

**T.C
YILDIZ TEKNİK ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ**

**İŞLETME ANABİLİM DALI
İŞLETME YÖNETİMİ TEZLİ YÜKSEK LİSANS PROGRAMI**

YÜKSEK LİSANS TEZİ

**YAPAY SİNİR AĞLARI UYGULAMASI KULLANILARAK
ÜRETİCİ FİYAT ENDEKSİ (ÜFE) DEĞERLERİNİN
ÖNGÖRÜ MODELLEMESİ VE ANALİZİ**

Ahmet Said Usta

3713011

İstanbul

2007

İÇİNDEKİLER

TABLO LİSTESİ.....	IV
ŞEKİL LİSTESİ.....	V
GRAFİK LİSTESİ.....	VI
KISALTMALAR.....	VII
ÖZET.....	IX
ABSTRACT.....	X

1. GİRİŞ.....	1
2. ENFLASYON	3
2.1. Enflasyonun Tanımı	3
2.2. Enflasyonun Çeşitleri	3
2.2.1. Talep Enflasyonu	3
2.2.2. Maliyet Enflasyonu	4
2.2.3. Yapısal Enflasyon	4
2.2.4. Stagflasyon (Enflasyon ve Durgunluk)	5
2.3. Enflasyonun Etkileri.....	7
2.3.1. Enflasyonun Başlıca Ekonomik Etkileri.....	7
2.3.1.1. Enflasyonun Verimlilik Üzerindeki Etkileri	7
2.3.1.2. Enflasyonun Faktör Gelirleri Üzerindeki Etkisi.....	7
2.3.1.3. Enflasyonun Tasarruflar ve Yatırımlar Üzerindeki Etkileri.....	8
2.3.1.4 Enflasyonun Ödemeler Dengesi Üzerindeki Etkisi.....	9
2.3.1.5 Enflasyonun Sermaye Tekelleşmeyi Arttırıcı Etkisi.....	9
2.3.2. Enflasyonun Mali Etkileri.....	10
2.3.2.1. Enflasyonun Vergi Gelirleri Üzerindeki Etkisi	10
2.3.2.2. Enflasyonun Vergi Kaçakçılığı Üzerindeki etkisi.....	10
2.3.2.3. Enflasyonun Bütçe Üzerindeki Etkisi.....	10
2.3.3. Enflasyonun Sosyal ve Siyasal Etkileri	11
2.3.3.1. Enflasyonun Gelir Dağılımını Bozucu Etkisi.....	11

2.3.3.2.	Enflasyonun Sosyolojik Değerleri Bozucu Etkisi	11
2.3.3.3.	Enflasyonun Sosyal Gerginliği Arttırıcı Etkisi	11
2.4.	Enflasyonu Önlemeye Yönelik İstikrar Programları	12
2.4.1.	Ortodoks İstikrar Programları.....	12
2.4.2.	Heteredoks İstikrar Programları	13
2.4.3.	Ek Önlemler	13
2.4.4.	Yapısal Reformlar.....	14
2.4.5.	Enflasyonun Önlenmesi Konusunda Şok Programlar	14
2.5.	Türkiye’de Enflasyon	15
2.6.	Türkiye’de ve Dünyada Enflasyonu Tetikleyen Genel Nedenler	17
2.7.	Fiyat Endeksleri (ÜFE ve TÜFE)	17
2.7.1.	Üretici Fiyat Endeksi (ÜFE)	18
2.7.2.	Tüketici Fiyatları Endeksi (TÜFE)	19
2.8.	Enflasyon Oranı	21
3.	YAPAY SİNİR AĞLARI (YSA)	22
3.1.	YSA Nedir?.....	23
3.2.	YSA’nın Yapısı: Elemanları ve Mimarisi.....	28
3.3.	YSA Çeşitleri	45
3.4.	Niçin YSA?	51
3.5.	Tarihsel Gelişim	53
3.6.	YSA, İstatistik ve Ekonomi	56
4.	MODELLER VE UYGULAMA.....	59
4.1.	Modeller.....	62
4.1.1.	YSA Modeli	62
4.1.2.	VAR Modeli.....	66
4.1.2.1.	VAR Modeli Uygulaması	69
4.1.3.	ARMA Modeli	72
4.1.3.1.	ARMA Modeli Uygulaması	74
5.	ÖNGÖRÜ DEĞERLENDİRMESİ & MODEL KARŞILAŞTIRMASI	77
5.1.	Modellerin Kıyaslanması	81
6.	SONUÇ.....	87

KAYNAKLAR	89
Ek 1. Durdurma Kriteri	94
Ek 2. YSA'ların Çalışma Şekli İçin Örnek Çözüm	95
Ek 3. Gizli Nöron Sayısı İçin Üst Limit Kriteri	96
Ek 4. Öğrenme Kuralları	97
Ek 5. XOR Problemi	99

TABLO LİSTESİ

Tablo 4.1: Fiyat Modeli Değişkenlerine Ait Durağanlık Testleri.....	69
Tablo 4.2: VAR Modeli Tahminleri.....	71
Tablo 4.3: ARMA Modeli Tahminleri.....	75
Tablo 5.1: Öngörü Hatalarına Ait Temel İstatistikler.....	85
Tablo 5.2: Öngörü Doğruluk Ölçüleri.....	86

ŞEKİL LİSTESİ

Şekil 3.1: YSA Mimarisinin Temel Elemanları.....	25
Şekil 3.2: Sinir Sisteminin Blok Diyagramı.....	29
Şekil 3.3: Biyolojik Nöronun Genel Yapısı ve İşlevleri.....	31
Şekil 3.4: Yapay Nöronun Genel Yapısı.....	32
Şekil 3.5: Yapay Nöronun Detaylı Yapısı.....	34
Şekil 3.6: En Çok Kullanılan Transfer Fonksiyonları.....	36
Şekil 3.7: Transfer Fonksiyonunun Çalışma Yapısı.....	37
Şekil 3.8: YSA'ların Genel Yapısı.....	38
Şekil 3.9: Geri Yayılma Bağlantı Yapısı.....	39
Şekil 3.10: İleri Beslemeli ve Geri Beslemeli Ağ Yapıları.....	46
Şekil 3.11: İleri Beslemeli Geri Yayılma Ağların Genel Yapısı.....	47
Şekil 3.12: Eğitim Sürecindeki Sinyal Çeşitleri.....	48
Şekil 4.1: YSA Modelinin Mimarisi.....	63

GRAFİK LİSTESİ

Grafik 2.1: Talep Enflasyonu.....	3
Grafik 2.2: Maliyet Enflasyonu.....	4
Grafik 4.1 Aylık Enflasyon Oranı.....	60
Grafik 4.2: Eğitim Süreci İçinde MSE'nin Değerleri.....	65
Grafik 4.3: YSA Modeli Öngörülleri.....	66
Grafik 4.4: VAR Modeli Öngörülleri.....	72
Grafik 4.5: ARMA Modeli Öngörülleri.....	76
Grafik 5.1: Örneklem İçi Öngörü Karşılaştırması.....	83
Grafik 5.2: Örneklem İçi Öngörü Hataları Karşılaştırması.....	83
Grafik 5.3: Örneklem Dışı Öngörü Karşılaştırması.....	84
Grafik 5.4: Örneklem Dışı Öngörü Hataları Karşılaştırması.....	84

KISALTMALAR

ABD	:	Amerika Birleşik Devletleri
ADF	:	Geliştirilmiş Dickey-Fuller Durağanlık Testi
AR	:	Oto Regresif Yapı
ARIMA	:	Oto Regresif Bütünleşik Hareketli Ortalama
ARMA	:	Oto Regresif Hareketli Ortalama
ART	:	Adaptif Rezonans Teorisi
Bkz.	:	Bakınız
DİE	:	Devlet İstatistik Enstitüsü
GSYİH	:	Gayri Safi Yurtiçi Hasıla
GYRSA	:	Geri Yayılma Yapay Sinir Ağı
HKT	:	Hata Kareleri Toplamı
IMF	:	Uluslararası Para Fonu
iid	:	Benzer Şekilde Bağımsız Dağıtılmış
İMKB	:	İstanbul Menkul Kıymetler Borsası
M2Y	:	Geniş Para Tanımı (Vadeli + Vadesiz TL Mevduat + Döviz Tevdiat Hesabı)
MA	:	Hareketli Ortalama
MAE	:	Ortalama Mutlak Hata
MAPE	:	Ortalama Mutlak Yüzde Hata
ME	:	Ortalama Hata
MPE	:	Ortalama Yüzde Hata
MSE	:	Ortalama Hata Kareleri Toplamı
MSPE	:	Ortalama Yüzde Hata Kareleri Toplamı
R ²	:	Korelasyon Katsayısı
RMPSE	:	Ortalama Yüzde Hata Kareleri Toplamı Kökü
RMSE	:	Ortalama Hata Kareleri Toplamı Kökü
TCMB	:	Türkiye Cumhuriyeti Merkez Bankası
ÜFE	:	Üretici Fiyat Endeksi
VAR	:	Vektör Otoregresyon

YSA : Yapay Sinir Ađı

ÖZET

Ekonomide, uygulama zaman içerisinde önemini artırırken, metodolojik gelişmeler de birbirini takip etmektedir. Günümüzde, artık, gerek politik amaçlı olsun gerekse öngörü amaçlı olsun uygulamalı ekonomik analiz yoğun bir şekilde kullanılmaktadır ve ekonomi alanı istatistik alanından giderek artan oranda yararlanmaktadır.

Gelişen teknolojiye paralel olarak artan işleme ve hesaplama gücü ile birlikte karmaşık simülasyonların yapılması ve gelişmiş yapay zeka algoritmaları kullanılarak temel kriterlere dayalı olarak geleceğe dönük tahmini modellemeleri gerçekleştirmek mümkün hale gelmiştir. Bu modellemelerin gerçekleştirilmesini sağlayan önemli bir uygulama alanı ise Yapay Sinir Ağlarıdır.

Bu çalışmada, yeni bir yöntem olan Yapay Sinir Ağları (Artificial Neural Networks) teknolojisi incelenmekte, öngörü modellemesi tekniği olarak Türkiye ekonomisine ait bir makroekonomik değişkene uygulanmakta ve başka yöntemlerle karşılaştırmalı olarak performans değerlendirilmesi yapılmaktadır.

ABSTRACT

By the process of interaction between economics and statistics structural modeling and forecast modeling has an important role. Forecast modeling is importance because of its role in the decision mechanisms. These mechanisms can be considered in two groups. While there exist some studies about measuring and improving the forecast accuracy on the one side, there are some significant advances about new forecasting techniques on the other side.

In line with these advances, some new forecasting methodologies have revealed. One of the most important new methodologies is the Artificial Neural Networks (ANN) technique. The ANN technique can be described as an information processing paradigm inspired by the way the brain processes information. It has been used widely in many different fields. This method, which is characterized as the universal function approximate in the literature, has many important features like ability to learn from data, nonlinearity, generalization etc.

In this study, the ANN technique is analyzed as the forecast modeling technique for a macroeconomic variable. Basically, ANN modeling technique is applied to Producers' Price Index (PPI) of the Turkish economy. Additionally, the results of the ANN methodology is compared with some widely used econometric techniques which have high forecasting power. Then, forecasting performance of the ANN model is compared with forecasting performance of the Vector Autoregression (VAR) and Box-Jenkins modeling techniques (ARMA). Evaluation of the results obtained using the ANN methodology indicated that the ANN models can provide satisfactory forecasting performance. Additionally, comparison of the ANN and traditional methodologies (VAR and Box-Jenkins) shows that the ANN modeling technique has a superior forecasting performance.

1. GİRİŞ

Ekonomik uygulamalar zaman içerisinde önemlerini artırırken, metodolojik gelişmeler de birbirini takip etmektedir. Günümüzde, artık, gerek politik amaçlı olsun gerekse öngörü amaçlı olsun uygulamalı ekonomik analizler yoğun şekilde kullanılmaktadır ve ekonomi istatistik biliminden ve yöntemlerinden giderek artan oranda yararlanmaktadır.

Politik bir takım kriterler göz ardı edildiği takdirde, günümüz ekonomilerinin karar süreçlerinde öngörü modellemesinin önemli bir rol üstlenmesi doğal bilimsel gelişimin bir sonucu olarak karşımıza çıkmaktadır. Makro politikaların oluşturulması ve/veya uygulanmasından, yatırım tercihlerinin belirlenmesine kadar ekonominin her kesiminde öngörü modellemesi önem kazanmıştır.

Doğru tahminin (veya öngörünün) başarılı kararları beraberinde getireceği ve bu şekilde fayda sağlamanın en üst düzeye çıkartılabileceği gerçeği, öngörü modellemesine olan ilgiyi artırmaktadır. Artan ilgi ile birlikte, bu alanda her geçen gün önemli gelişmeler olmaktadır. Ortaya çıkan gelişmelerden bir tanesi öngörü doğruluğuna yönelik çalışmaların artış göstermesidir. Öngörü modellemesinde kullanılabilecek yöntemlerin çeşitliliği, model seçiminde bazı zorlukları da beraberinde getirmiştir. Amaç öngörü performansını artırmak olduğundan model seçiminde zaman zaman teorik kriterler yerine öngörü performansına yönelik kriterler ön plana çıkmaktadır. Hatta öngörü doğruluğu bazen o kadar önem kazanmaktadır ki ekonomik teoriler ve bunların gerektirdiği kısıtlar bir tarafa bırakılabilmektedir. Öngörü doğruluğuna yönelik çalışmalar, çeşitli modellerin öngörü doğruluklarını değerlendirmeye ve karşılaştırmaya yönelik yöntemler üzerinde yoğunlaşmıştır. Diğer taraftan, alternatif bir yöntem olarak farklı modellerden alınan öngörülerin birleştirilmesi ile öngörü kalitesinin yükseltilmesine yönelik çalışmalar da mevcuttur.

Öngörü modellemesine karşı ilginin artması, model çeşitliliğini de beraberinde getirmiştir. Büyük ölçekli yapısal makroekonometrik modeller, basit regresyon modelleri, Box-Jenkins (ARMA) modeli ve VAR (Vector Autoregression) modelleme tekniği gibi birçok istatistiksel ve ekonometrik yöntem öngörü modellemesinde kullanılmaktadır. Bu bilinen modelleme teknikleri yaygın şekilde kullanılırken aynı zamanda bazı yeni

metodolojiler de ön plana çıkmaktadır. Yapay Sinir Ağları (YSA) tekniği de bu yeni teknikler arasında en önemlilerinden birisidir.

YSA modelleme tekniği günümüzde birçok alanda yaygın bir şekilde kullanılmaya başlanmıştır. Basit bir şekilde insan beyninin çalışma şeklini taklit eden YSA'lar Yapay Zekâ çalışmaları içinde önemli bir yere sahiptir. “Evrensel Fonksiyon Yakınsayıcı Yöntem (Universal Function Approximators)” olarak tanımlanan YSA metodolojisi veriden öğrenebilme, genelleme yapabilme, sınırsız sayıda değişkenle çalışabilme vb. birçok önemli özelliğe sahiptir. Bu özellikleri sayesinde oldukça önemli avantajlar sağlayan YSA metodolojisi diğer alanlarda olduğu gibi öngörü modellemesi alanında da yaygın bir şekilde kullanılmaktadır.

Bu çalışmada, yeni bir yöntem olan Yapay Sinir Ağları (Artificial Neural Networks) teknolojisi incelenmekte, öngörü modellemesi tekniği olarak Türkiye ekonomisine ait bir makroekonomik değişkene uygulanmakta ve başka yöntemlerle karşılaştırmalı olarak performans değerlendirmesi yapılmaktadır.

Bu kapsamda, çalışmanın ikinci bölümünde enflasyon kavramı ele alınacak ve çeşitleri ile etkileri üzerinde durulduktan sonra engellenmesine yönelik istikrar programları ele alınacaktır. Üçüncü bölümünde Yapay Sinir Ağları teorisi ele alınacaktır. Bir taraftan YSA teknikleri genel olarak ele alınırken diğer taraftan daha sonra kullanılacak modelin alt yapısı oluşturulmaktadır. Dördüncü bölüm değişik modelleme yöntemleri ile tahmin edilen modellere ve model öngörülerine ilişkin bilgileri içermektedir. Beşinci bölümde, çalışmanın amacı çerçevesinde, bir performans değerlendirmesine yer verilmekte ve son bölümde ise elde edilen sonuçlar tartışılmaktadır.

2. ENFLASYON

2.1. Enflasyonun Tanımı

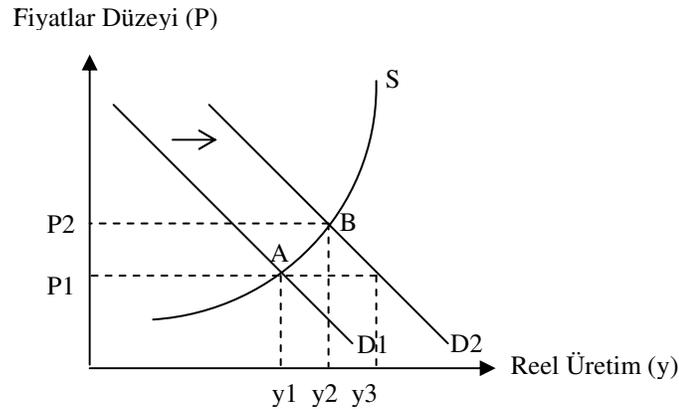
Enflasyon, fiyatlar genel seviyesindeki devamlı ve hızlı artışlar olarak tanımlanır. Bir başka tanımla enflasyon, parasal gelirdeki fiili büyümenin, üretimdeki fiili büyümeden daha yüksek olmasıdır.

Teorik açıklamalar ile halkın enflasyon anlayışı bazı noktalarda farklılıklar göstermektedir. Halk, her fiyat yükselişini enflasyon olarak bilirken, ekonomi bilimi, devamlılık gösteren ve belli bir oranın üzerine çıkan fiyat artışlarını enflasyon olarak tanımlamaktadır. Yani fiyatların bir defalık yükselmesine enflasyon değil fiyat artışı denir.

2.2. Enflasyonun Çeşitleri

2.2.1. Talep Enflasyonu

Talep enflasyonu aşağıda Grafik 2.1 de gösterildiği gibi toplam arz sabitken toplam talebin artması nedeniyle oluşmaktadır.



Grafik 2.1: Talep Enflasyonu

(Cem Alpar. İktisat. S.128)

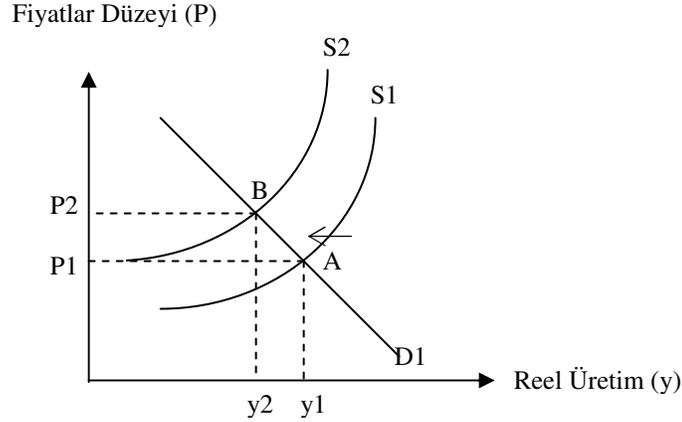
Şekilde ekonomi başlangıçta S toplam arz ve D1 toplam talep eğrilerinin kesiştiği A noktasında dengede olsun. Bu denge noktasında fiyat düzeyi Y1 dir. Ekonomi bu durumda iken toplam harcamaların arttığını varsayalım. Talepte meydana gelen bu artış toplam talep eğrisinin D1 den D2 ye doğru kayması ile gösterilmiştir.

Toplam talebin bu şekilde sağa kayması ile P1 fiyat düzeyinde Y1-Y3 kadar aşırı talep meydana gelecek, ekonomide hem fiyatlar hem de üretim yükselerek A noktasından B

noktasına gelecektir. Fiyatların bu şekilde P1 den P2 ye yükselmesi talep kayması nedeniyle meydana geldiğinden bu duruma “Talep Enflasyonu” denmektedir.

2.2.2. Maliyet Enflasyonu

Bir ekonomide mal ve hizmetlere olan talep sabitken arzın azalması yani sola kayması nedeni ile de enflasyon oluşabilir. Bu durumu Grafik 2.2 de inceleyebiliriz.



Grafik 2.2: Maliyet Enflasyonu
(Cem Alpar. İktisat. S.129)

Şekilde başlangıçta D1 talep eğrisi ile S1 arz eğrisinin kesiştiği A noktasında ekonomi dengededir. Reel üretim düzeyi y_1 ve fiyatlar genel düzeyi P_1 dir. Ekonomide mal ve hizmetlere yönelik talepte bir değişme yokken maliyet artışı sebebiyle toplam arzın azaldığını yani S1 den S2 ye sola doğru kaydığını varsayalım. Bu kayma maliyetleri artan firmaların aynı miktar mal ve hizmeti daha yüksek bir fiyattan üretmeye razı olacaklarını gösterir.

Maliyetlerin artmasıyla meydana gelen arz kayması sonucu P_1 fiyatı seviyesinde ekonomide “Talep Fazlası” meydana gelecek, buna bağlı olarak fiyatlar yükselerek ekonomi A noktasından B noktasına gelecektir. Fiyatların bu şekilde arz kaymasına bağlı olarak yükselmesine “maliyet enflasyonu” denir.

2.2.3. Yapısal Enflasyon

Ekonomik yapının esneksizliğinden kaynaklanan enflasyon, özellikle azgelişmiş ülkelerde enflasyonun önemli bir nedeni olarak gösterilir.¹ Ekonomik yapının katılığı sonucu belli sektörlerdeki üretim, bu sektörlerde ortaya çıkan talep değişmelerine kısa

¹ İlker Parasız, Makro Ekonomi, Ezgi Kitabevi, Bursa, 1998. s.213

zamanda uyum gösterememektedir. Uyum sürecinin yavaş işlemesinin nedenleri arasında kaynak hareketliliğinin düşük olması, sermaye, döviz, nitelikli iş gücü yetersizliği gibi etkenler gösterilebilir. Dolayısıyla, ekonomide genel bir talep fazlası bulunmamakla birlikte, belirli bir sektörün ürünlerine karşı çıkan talep artışları üretim artışına değil bu sektörlerde fiyat ve ücret artışlarına yol açmaktadır. Oysa bu etkiler tek yönlü olarak ortaya çıkarlar yani talebin arttığı endüstrilerde ücretler ve fiyatlar yükselirken talebin düştüğü endüstrilerde ücret ve fiyat düşüşleri olmaz. Böylece kısmi talep genişlemesi ve ekonomik yapının katılığı sonucu ortaya çıkan fiyat ve ücret artışları para arzının sürekli artırıldığı durumlarda giderek tüm ekonomiye yayılır ve genel bir enflasyona dönüşür.²

ABD’de 1953-1958 dönemi için yapılan bir araştırmada fiyat yükselişinin oligopol kuran sanayilerin davranışından doğduğu saptanmıştır. Bu sanayi kollarının ise demir-çelik, mekanik, otomobil, kauçuk sanayileri olduğu görülmüştür. Oysa 1942-1947 yılları arasında fiyatlar rekabetçi sanayi ve işletmelerce belirleniyordu. Bazı yıllarda rekabetçi pazarlarda fiyatların düşmesine karşılık eksik rekabetçi pazarlarda fiyatlar yükselmeye devam etmiştir. Bu fiyat yükselişlerinde talep ve maliyetler önemsiz kaldığından bunlara “Yapısal Enflasyon” denmektedir.³

2.2.4. Stagflasyon (Enflasyon ve Durgunluk)

1953-1967 döneminde batının belli başlı sanayi ülkelerinde enflasyon oranının yıllık ortalaması %2’nin biraz üzerinde seyretmiştir. Ama 1968 yılından sonra durum büyük ölçüde değişmeye başlamıştır. Bir yandan ücretler ve hammadde fiyatları hızla artarken petrol dört kat yükselmiştir. Böylece eşine rastlanmayan bir enflasyon dönemine geçilmiştir. 1973 yılından sonra iki yıl içinde tüm OECD ülkelerinde enflasyon oranı %26’yı bulmuştur. Bu oran İngiltere’de %44’e ulaşmış Japonya onu %38 ile izlemiştir.⁴

Enflasyon ve durgunluğun birlikte ortaya çıkması hem yeni bir olaydır hem de açıklaması oldukça zordur. Bu açıklama tek bir nedenle yapılamaz.

Dar anlamda stagflasyon ABD’de 1970 yılının ilk yarısı ve İtalya’da 1969’un ilk yarısı hariç İngiltere’den başka bir yerde görülmemiştir. Özellikle dış ekonomik denge

² İlker Parasız, Makro Ekonomi, Ezgi Kitabevi, Bursa, 1998. s.213- 214

³ Merih Paya, Para Teorisi ve Politikası, Filiz Kitabevi, 2.Baskı, İstanbul, 1998. s76

⁴ Paya, s81

olmak üzere İngiltere’de genel dengeyi sağlamak amacıyla toplam talebin kısılması politikası enflasyonu önlemeye yetmemiştir.⁵

P.Coulbois stagflasyonu şöyle tanımlamaktadır: “Nominal talep artışındaki bir düşme karşısında fiyatlardaki duyarsızlığa stagflasyon denir.” Yeni bir konjonktürel durum olan stagflasyonun zaman ve yer bakımından sınırlı olduğu görülmektedir. Çünkü olay, uluslar arası bir niteliğe bürünmeden yalnız İngiltere ve ABD’yi etkilemiştir. Avrupa ülkeleri bu olayın dışında kalmışlardır. 1961-1965 döneminde ABD’de büyüme fiyat istikrarı içinde gerçekleşmiştir. Türkiye 1977’den sonra zaman zaman stagflasyon dönemleri yaşamıştır.⁶

Bu ana başlıklar haricinde enflasyon oranı kriterine göre enflasyon üçe ayrılır.

1. *İlmlı Enflasyon:* Yıllık %3-%4 gibi sürekli fiyat artışlarına ılımlı enflasyon denir.⁷ Bu tip bir enflasyonun ekonomi faaliyeti özendirdiği ve bu nedenle de faydalı olduğu savunulmaktadır.

2. *Yüksek Enflasyon:* Enflasyon oranının yıllık %50’leri aşması ve üç rakamlı hale gelmesiyle yüksek oranlı enflasyon ortaya çıkar.⁸ 1975 sonrasında Türkiye böyle bir enflasyon dönemi içine girmiştir.

3. *Hiperenflasyon:* Çok yüksek oranlı bir enflasyondur. Savaş, ihtilal, durumu veya anormal koşullarda ortaya çıkar.⁹ Hiperenflasyon durumunda fiyatlar genel düzeyindeki artış %50’lerin üzerine çıkar ve sonunda para sistemi çöker. 1914-1923 döneminde Almanya tipik bir hiper enflasyon yaşamıştır. Bu dönemde, Almanya’da fiyatlar bir milyon kat artmıştır. E. Waceman’ın hesaplarına göre, bir milyon markla 1919’da orta ölçekli bir fabrika, 1920’de bir villa, 1921’de küçük bir ev ve 1922’de bir otomobil satın alınabiliyorken, 1923’ün ilk yarısında sadece bir takım elbise satın alınabilmiştir. Bu yılın ikinci yarısında ise mark bir paçavra haline gelmiş ve lokantalarda yemek fiyatları üç-beş defa değişmiştir.¹⁰

⁵ Merih Paya, Para Teorisi ve Politikası, Filiz Kitabevi, 2.Baskı, İstanbul, 1998. s.82

⁶ Paya, s.82

⁷ Halil Seyidoğlu, Ekonomik Terimler Ansiklopedik Sözlük, 2. Baskı, İstanbul, 1999. s.67

⁸ Seyidoğlu, s.134

⁹ Seyidoğlu, s.58

¹⁰ D.N. Gujarati, Basic Econometrics, McGraw-Hill Inc. 1995. s.211

2.3. Enflasyonun Etkileri

Fransızca bir kelime olan enflasyon şişkinlik anlamına gelir.¹¹ İktisatta enflasyon denince: “fiyatlar genel düzeyindeki devamlı yükselmeler” olarak anlaşılır. Fiyatların bir defalık yükselmesine enflasyon değil fiyat artışı denir.¹² Enflasyon; sosyal, siyasal, ekonomik sorunlara yol açan çok boyutlu bir sorundur. Enflasyonun bu olumsuz etkilerini aşağıdaki başlıklar altında incelememiz mümkündür.

2.3.1. Enflasyonun Başlıca Ekonomik Etkileri

Enflasyon, faktör gelirleri, tasarruf ve yatırımlar, ödemeler dengesi, sermaye üzerinde olumsuz etkilerde bulunur ve bu alanda dengesizliklere yol açar.

2.3.1.1. Enflasyonun Verimlilik Üzerindeki Etkileri

Enflasyonun ilk etkilerinden birisi verimlilik kaybına yol açan etkisidir. Buna “ayakkabı eskitme maliyeti-shoe leather cost” denmektedir.¹³ Çünkü enflasyonist ortamda insanlar ellerinde nakit para tutmak istemeyecek ve ihtiyaçlarını karşılamak için sürekli bankaya gidip gelme zorunda kalacaklardır. Bu da iş verimini düşürerek insanların boş zaman kayıplarını arttıracaktır bu yüzden buna ayakkabı eskitme maliyeti adı verilmektedir. İş kaybı, verimlilik kaybı, zaman kaybı olarak ifade edilebilecek bu maliyetleri, ev ve iş yerlerindeki gereksiz zihni meşguliyet ve benzeri kayıplarla da genişletmek mümkündür.¹⁴

2.3.1.2. Enflasyonun Faktör Gelirleri Üzerindeki Etkisi

Enflasyonun etkin olduğu dönemlerde fiyatlar nominal ücretlerden daha hızlı arttığından reel ücretler devamlı düşme göstermektedir. Nominal ücretleri reel ücretler düzeyine çıkartmak için başvuru katsayı artışı ve toplu sözleşmeler, enflasyonun yıkıcı etkilerini giderecek büyüklükte olmamaktadır. Zaten bu ve buna benzer karakterdeki istekler talep ve maliyet enflasyonuna yol açar endişesiyle ücret gelirleri enflasyon artışının altında tutulmakta ve enflasyonun gerisinde kalmaktadır.¹⁵

¹¹ İlker Parasız, Öakro Ekonomi, Ezgi Kitabevi, Bursa 1998. S.176

¹² Besim Üstünel, Makro Ekonomi, Mısırlı Matbaacılık, 5. Baskı, İstanbul 1990. S. 117

¹³ Üstünel, s.118

¹⁴ Üstünel, s.118

¹⁵ Üstünel, s.118

Faiz ve kira gelirleri üzerinde enflasyonun meydana getirdiği aşınmanın önlenmesi, akitlerin bir enflasyon primi içerebilmelerine bağlıdır. Böylece nominal faiz oranı ve kira enflasyon oranı dahilinde yükselecek reel faiz oranı ve kira sabit kalacaktır.¹⁶

İşletmeler ve karlar üzerinde ilk bakışta enflasyon olumlu etki yapıyor gibi görünmektedir. Bunun sebepleri:

- Öz sermaye ve sabit varlıkların satın alma değerleri üzerinden işlem yaparak yıpranma payı ayrılması.
- Enflasyon nedeniyle nominal satış gelirlerinin artmakta olmasıdır.

Ancak üretim süresinde karşılaşılan maliyet artışları, satış fiyatlarına yansıtılabildiği sürece, nominal karlarda görülen kabarma, yıpranma paylarının gerçekçi bir biçimde hesaplanmamasından doğmuş olacaktır. Bu karların dağıtılması ise öz sermayenin tüketilmesi anlamına gelir. Dolayısıyla enflasyon, nominal karın yükselmesine, reel işletme sermayesinin eksilmesine yol açan bir süreçtir. Enflasyonunun üretim faktörlerinin gelirlerini belirsizleştirmesi bu faktör sahiplerinin ileriye yönelik planlarını alt üst etmekte ve üretim tüketim dengesinin bozulmasına yol açmaktadır.¹⁷

2.3.1.3. Enflasyonun Tasarruflar ve Yatırımlar Üzerindeki Etkileri

Enflasyon, gönüllü tasarrufları azaltmaktadır. Fiyatların devamlı yükselmesi ve tasarrufun getirisi olan faizin bu artışı izleyememesi, daha doğrusu negatif reel faiz, tasarrufların başka alanlara kaymasına yol açmaktadır. Bu birikimler ya verimsiz yatırım alanları olan altına, gayri menkule ya da enflasyonu daha da kamçılacak tüketim harcamalarına yönelmektedir. Sonuç olarak yatırımlar için gerekli kaynaklar ekonominin kendi içinde sağlanamaz hale gelmektedir.¹⁸

Yatırımlar üzerinde de enflasyonun olumsuz etkileri vardır. Kamu kesiminin ve özel kesimin yatırımları devamlı fiyat yükselmeleri nedeniyle başlangıç maliyetlerinin çok üzerinde gerçekleşmektedir. Enflasyon, işletmelerin yatırımlarının zamanında ve beklenen maliyetlerle gerçekleşmesini önlediğinden arz talep dengesini bu yüzdende bozmaktadır. Ayrıca spekülatif kazançların karlılık oranının yüksekliği bu yöndeki girişimleri arttırmış,

¹⁶ Besim Üstünel, Makro Ekonomi, Mısırlı Matbaacılık, 5. Baskı, İstanbul 1990. S. 118

¹⁷ Üstünel, s.119

¹⁸ Üstünel, s.120

ekonomik fonlar üretim kaynaklarının geliştirilmesi, genişletilmesi yerine spekülasyon faaliyet alanlarına yöneltilmiştir.¹⁹

Arz yetersizliği ve aşırı talep mal kıtlıklarının, kara borsanın sebebi olurken bu malları ellerinde bulunduranlara haksız kazanç kapılarını aralamıştır.

Bu nedenlerle yatırımların rasyonel ve etkin dağılımı bozulduğu gibi kaynakların verimli alanlarda değerlendirilmesi de sağlanamamaktadır.

2.3.1.4. Enflasyonun Ödemeler Dengesi Üzerindeki Etkisi

Enflasyon sonucu iç piyasada üretilen malların fiyatları yükseldiğinden bunların ihracat imkanları daralmaktadır. Dolayısıyla ihracatı teşvik gayesi ile bir çok suni yöntemler (ihracatta vergi iadesi, düşük faizli ihracat kredisi verilmesi, vergisiz hammadde ve makine ithali vb...) uygulanmaktadır.²⁰

Diğer taraftan ithal malların fiyatları dengeli kaldığı sürece bunlara olan talep hızla artmaktadır. Gelişmekte olan ülkelerde gösteriş tüketimi eğiliminin kuvvetli olması nedeniyle zaten fazla olan ithal malları kullanım oranının, fiyatlardaki düşüklükle desteklenmesi döviz rezervlerinin erimesine yol açmaktadır.²¹ İhracatın azlığı ve ithalatın fazla vermesine sebep olan enflasyon ödemeler dengesine olumsuz etkiler yapmaktadır. İş fiyatlarının yükselmesine neden olan enflasyon döviz kurları ayarlanmadığı takdirde ihracatı azaltmak ve ithalatı arttırmak suretiyle ülkenin yoksullaşmasına yol açmaktadır.

2.3.1.5. Enflasyonun Sermaye Tekelleşmeyi Arttırıcı Etkisi

Enflasyonist bir ortamda bazı endüstri dallarının karlılıklarında artışlar olsa da ekonominin bütünü açısından ortalama kar hadlerinde düşüş gerçekleşir. Bu da serbest piyasa ekonomilerinde yatırımları olumsuz yönde etkiler. Örneğin yıpranma payları yıpranma yatırımlarını karşılamayacak kadar küçülür. Sermaye malları stokunu eski düzeyde tutabilmek için ayrılmış olan amortismanlardan daha büyük bir kaynağa ihtiyaç doğar. Öte yandan enflasyondan doğan talep artışını karşılayabilmek için kapasite artırımı gerekir. Bu yatırımların finansmanı konusunda firmaların başvurabilecekleri kaynaklar fazla değildir. Hisse senetleri karlı olmadığında fazla alıcı bulamaz. Faiz oranlarının

¹⁹ Besim Üstünel, Makro Ekonomi, Mısırlı Matbaacılık, 5. Baskı, İstanbul 1990. S. 120

²⁰ Üstünel, s.120

²¹ Üstünel, s.120

yüksekliği borç maliyetini yükseltmektedir. Bu sebeple firmalar iç kaynaklara başvurmak zorunda kalmakta ve bu kaynakların da yetersiz olması sebebiyle ya emek yoğun yatırımlar ya da firmalar arası ortak girişimler artar bu da tekelleşmeye yol açar.²²

2.3.2. Enflasyonun Mali Etkileri

Enflasyon mali açıdan aşağıdaki sorunlara yol açar.

2.3.2.1. Enflasyonun Vergi Gelirleri Üzerindeki Etkisi

Enflasyon sonucu vergi gelirlerinin düştüğü gözlenmektedir. Enflasyon dönemlerinde nominal gelirlerde artış olduğundan vergi gelirlerinde reel bir artış olup olmadığı enflasyondan doğan gelir artışlarının ne kadarını massedebildiğine bağlıdır. Ülkemizde son yıllarda vergi gelirlerinde reel bir artış söz konusu değildir. Özellikle sabit oran ve matrahlı vergiler enflasyonun etkisiyle aşınmakta ve önemli vergi kaybına neden olmaktadır.²³

2.3.2.2. Enflasyonun Vergi Kaçakçılığı Üzerindeki etkisi

Enflasyon reel işletme sermayelerini aşındırıcı bir özelliğe sahip olması sebebiyle işletmeler gerçek işletme sermayelerini koruyabilmek için vergi kaçırma yoluna gitmektedirler. Eğer bunu yapmazlarsa gerçek işletme sermayelerinin bir gün tükendiğini görmek durumunda kalacaklardır. Bu nedenle enflasyon, vergi kaçığı teşvik edici ve gizlenmesine yardımcı olucu bir etken olarak karşımıza çıkmaktadır.²⁴

2.3.2.3. Enflasyonun Bütçe Üzerindeki Etkisi

Yükselen fiyatlar kamu harcamalarını maliyetini yükseltmekte fakat gelirlerin enflasyon oranına endekslenmemesi sebebiyle reel gelirleri azaltmaktadır. Böylece devamlı açık veren bir bütçe ortaya çıkmaktadır. Devletin merkez bankasına olan borçları kabarır bu da dengesizliği arttırır.²⁵

Böylece enflasyon bütçe açıkları doğurmakta bütçe açıkları da enflasyonu besleyerek bir kısır döngü oluşturmaktadır.

²² Besim Üstünel, Makro Ekonomi, Mısırlı Matbaacılık, 5. Baskı, İstanbul 1990. S. 121

²³ Üstünel, s.121

²⁴ Üstünel, s.121

²⁵ Üstünel, s.121

2.3.3. Enflasyonun Sosyal ve Siyasal Etkileri

Enflasyon, sosyal ve siyasal sorunlara yol açmakta ve sosyal dengenin bozulmasına yol açmaktadır.

2.3.3.1. Enflasyonun Gelir Dağılımını Bozucu Etkisi

Enflasyon dönemlerinde dar ve sabit gelirliler zarar görürken büyük tüccar ve sanayici, serbest meslek erbabı, mal darlığını ve üretim yetersizliğini kullanarak spekülâtif kar peşinde koşanlar karlı çıkmaktadırlar. Servetlerini para olarak ellerinde tutanlar paranın satın alma gücü oranında servetlerinden kaybederlerken, servetini; gayrimenkul, altın, dayanıklı tüketim malı şeklinde ellerinde tutanlar bu süreçten kazançlı çıkmaktadırlar. Dolayısıyla elde mal tutmak para tutmaktan daha karlı duruma gelmekte bu da kıtlığa ve karaborsaya yol açmaktadır. Enflasyon dönemlerinde borçlu olanla, enflasyon oranında kar ederken alacaklı olanlar bu oranda zarar etmektedirler.²⁶

Gelir bölüşümünü üreticiler ve spekülâtörler lehine, sabit gelirliler aleyhine değiştiren enflasyon, gelir dağılımındaki dengesizliği zamanla arttırarak toplumda yoksulların sayısını arttırmakta ve sınırlı sayıdaki insanların aşırı zenginleşmesine yol açmaktadır.²⁷

2.3.3.2. Enflasyonun Sosyolojik Değerleri Bozucu Etkisi

Üretim yetersizliği ve her şeyin satılabildiği bir piyasa mal ve hizmet kalitesinin düşmesine neden olmaktadır. Kara borsa eğilimi artmakta spekülâtif ve haksız kazançlarla zengin olmanın yolunu bulanların lüks ve israf harcamaları çoğalmaktadır. Bu, bir taraftan toplumun ahlaki ve manevi değerlerinde bozucu etki yaparken; diğer taraftan kolay zengin olma hevesini kamçılıyarak halk sağlığı mal kalitesi, insan haysiyeti gibi yüce değerlerin horlanmasına yol açmaktadır. Borçlunun daha menfaatli hale gelmesi insanlar arası ilişkilerde menfaat duygusunu öne çıkarmakta tufeciliği yaygınlaştırmaktadır.²⁸

2.3.3.3. Enflasyonun Sosyal Gerginliği Arttırıcı Etkisi

Hızlı enflasyonun yaşandığı bir toplumda bir tarafta haksız ve vergilendirilmemiş kazanç sahiplerinin lüks ve israf yaşantılarını sergileyen gazete sütunları, diğer tarafta iş bulma mutluluğuna eremeyenler ve geçinebilmek için mesaiye mesai katanlar vardır. Böyle

²⁶ Besim Üstünel, Makro Ekonomi, Mısırlı Matbaacılık, 5. Baskı, İstanbul 1990. S. 122

²⁷ Üstünel, s.122

²⁸ Üstünel, s.123

bir toplumda gerginlikleri azaltmak oldukça zordur, bunları istismar ederek kıvılcımları yangınlara dönüştürmek ise oldukça kolaydır. Aslında, bir ülkenin sosyal yapısını değiştirmek için karşılaşılan zorlukları bertaraf etmede kullanılan en güzel araç enflasyondur.²⁹

Netice olarak bir çok iktisadi, siyasi, sosyal ve ahlaki sorunlara yol açan yüksek enflasyonla bir toplumun varlığını sürdürmesi mümkün değildir. Her ne kadar enflasyonda toplumun bazı kesimleri karlı çıkıyor gibi görünse de sonuç olarak enflasyon toplumun bütün kesimlerini olumsuz olarak etkiler.³⁰

Dünya üzerinde karşılaşılan temel dengesizlik hali enflasyon olarak karşımıza çıkmaktadır. Bu nedenle ülkeler enflasyonu en önemli neden olarak görmektedirler. IMF gibi uluslar arası kuruluşlar da enflasyon sorunu ile karşılaşılan ülkelere yönelik istikrar programları önermektedirler.³¹

2.4. Enflasyonu Önlemeye Yönelik İstikrar Programları

Enflasyonu önlemeye yönelik programlar temelde ortodoks ve heteredoks programlar olarak ikiye ayrılmakta, bu programların ek önlemler ve yapısal reformlarla desteklenmesi önerilmektedir.³²

2.4.1. Ortodoks İstikrar Programları

Ortodoks (geleneksel) istikrar programları para ve maliye programları kullanarak iç ve dış dengeyi birlikte gerçekleştirmeyi esas alan programlardır. Bu programlar:³³

- Bütçe dengesinin sürekliliğini sağlamak
- Kambiyo kurunu sabitleştirmek
- Merkez bankasını bağımsızlaştırmak veya bağımsızlığını denetlemek
- Dış desteği sağlamak
- Toplumsal desteği sağlayıcı ortamı oluşturmak

²⁹ Besim Üstünel, Makro Ekonomi, Mısırlı Matbaacılık, 5. Baskı, İstanbul 1990. S. 123

³⁰ Üstünel, s.123

³¹ Üstünel, s.123

³² Üstünel, s.124

³³ Üstünel, s.124

2.4.2. Heteredoks İstikrar Programları

Heteredoks (çoklu) istikrar programları, ortodoks istikrar programları tedbirlerine ilave olarak uyguladıkları ücret ve fiyatlara doğrudan müdahale eden tedbirlerle üretim ve istihdam düzeyinde gerileme meydana getirmeden enflasyonu kısa sürede ve ani olarak aşağı çekmeye yönelik programlardır. Bu programlar bütün nominal çıpaları kullanarak ekonomik dengeyi sağlamaya çalışırlar.³⁴

Heteredoks istikrar programları enflasyon bekleyişlerinin hızla düşmesi için bir anahtar fiyatın temel olarak alınması ve bu konuda istikrarın sağlanması görüşündedir. Bu anahtar fiyata, “Program Çıpası” denilir. Bunun altında yatan sebep ise akıntıya kapılan bir geminin sürüklenmesini önlemek için denize atılan çapa gibi ekonomide dengeyi ve sürüklenmeyi önleyici bir rol oynamaktadır. Bu çıpa, döviz kuru, faiz oranı, para arzı, banka kredileri, ücretler olabilmektedir. Ancak uygulamada tek bir çıpa ya fazla yük yüklenmemesi için birden fazla çıpa seçilebilmektedir.³⁵

Bununla birlikte heteredoks istikrar programları:³⁶

- Kambiyo kurunun sabitleştirilmesi
- Para ve kambiyo kredi tavanlarının belirlenmesi
- Ücretlerin ve sözleşmelerin dondurulması ve gelir politikalarının uygulanması
- Geçici veya kısmi fiyat kontrollerinin uygulanması, gibi temeller üzerine

kurulmuştur.

2.4.3. Ek Önlemler

Her iki program uygulamasında da makro ekonomik dengeyi çabuk ve hızlı bir şekilde gerçekleştirmek amacıyla ek önlemler uygulanması gerekmektedir. Bu önlemler:³⁷

- Faiz oranlarını belirleme konusundaki şartların belirlenmesi
- Yeni bir para biriminin tedavüle çıkarılması veya sınırların atılması
- Likit varlıkların endekslenmesi veya dövize bağlanmasının önüne geçilmesi
- İç borcun yeniden yapılandırılması, bunun için işletmeler, bankalar ve hükümet

arasında kamu borçlarını düzenleyici esasların belirlenmesi.

³⁴ Besim Üstünel, Makro Ekonomi, Mısırlı Matbaacılık, 5. Baskı, İstanbul 1990. S. 124

³⁵ Üstünel, s.125

³⁶ Üstünel, s.125

³⁷ Üstünel, s.125

2.4.4. Yapısal Reformlar

İstikrar programı uygulayan ülkelerin tekrar böyle bir istikrar programı uygulayacak duruma düşmemesi açısından istikrar bozucu unsurları ortadan kaldırmayı amaçlayan uygulamalara da yapısal reformlar denilmektedir.³⁸

- Ödemeler bilançosundaki cari hesapların liberalize edilmesi (dış ticareti engelleyici kotalar, lisanslar gibi unsurların kaldırılması)
- Mali reformların yapılması (vergi, harcama transfer sistemleri)
- Ulusal finansal piyasalar ile sermaye piyasalarının engellerden arındırılması ve finansal aracılık için yeni kurumların oluşturulması
- Emek piyasalarındaki giriş çıkış engellerinin kaldırılması ve serbestleştirilmesi

2.4.5. Enflasyonun Önlenmesi Konusunda Şok Programlar

Uygulamada “şok hindi-cold turkey” olarak ifade edilen yaklaşım, nominal milli gelir artışındaki ani ve sürekli bir düşüşü ifade eder. Ekonominin belirli bir enflasyon oranında dengede olduğu bir durumda milli gelirdeki büyümenin aniden düşürülmesi halinde enflasyon oranında da belirli bir düşüş gerçekleşebilecektir.³⁹

Nominal milli gelirdeki büyümenin düşmesi toplam talep baskıları ile fiyatlar genel seviyesinde de düşmelere yol açabilecektir. Ancak milli gelirdeki düşme ile fiyatlar genel seviyesindeki düşme aynı oranda olmayabilecektir. Örneğin enflasyon beklentilerinin %10 ve reel milli gelirin 100 olduğu bir ekonomide nominal milli gelirdeki büyümenin %10 oranında düşürülmesi nominal milli gelirden %6’lık bir düşüş gerçekleştirebilecek, bu düşüşün dört puanı reel milli gelirden iki puanı da enflasyon genel seviyesinde görülebilecektir. Yani milli gelirdeki nominal bir artışın düşürülmesi aynı oranda fiyatlar genel seviyesini düşürmeyecek, etkileşim reel milli gelirden deha büyük, enflasyon seviyesinde daha küçük kalacaktır.⁴⁰

Şok politikalarının başarılı sonuçlar verebilmesi için şoktan sonra izlenecek politikaların güvenilirliğinin hızla yükselmesi gereklidir. Bu amaçla da kamu harcamalarındaki kesintilerin. Hemen devreye girmesi, vergi artışlarının gerçekleşmesi, talep baskısı oluşturan unsurların elimine edilmesi gerekmektedir. Yani şok milli gelir

³⁸ Besim Üstünel, Makro Ekonomi, Mısırlı Matbaacılık, 5. Baskı, İstanbul 1990. S. 126

³⁹ Üstünel, s.126

⁴⁰ Üstünel, s.126

büyümesinin azaltılmasının sağladığı ara avantajlar hemen enflasyonu meydana getiren unsurların ortadan kaldırılması için kullanılırsa uygulama başarılı olacaktır.⁴¹

2.5. Türkiye’de Enflasyon

Sürekli ve yüksek oranlı fiyat artışları olarak tanımlanan enflasyon, ekonomide makro ve mikro etkiler yaratır. Makro düzeyde ekonomi çarklarını aksatan enflasyon, mikro düzeyde de toplumsal sonuçlar doğurmaktadır.

Türkiye’de enflasyon, petrol fiyatlarından kaynaklanan dış şoklarla başlamış ve önlenemeyen bütçe açıkları ile yüksek düzeye çıkmıştır. Enflasyon ülkemizde birçok kaynaktan beslenmektedir. Bunlardan ilki, bütçe açıklarıdır (kamu gelir-gider dengesizliği). Hızlı nüfus artışı ile hızlı kalkınma ihtiyacının yarattığı alt yapı yatırımları, sürekli artan enflasyon beklentisi ve TL’nin yabancı paralarla ikamesi (yabancı paraların TL. yerine kullanılıyor olması. Örneğin, dolarla ödenen kiralar.) enflasyonu besleyen etkenlerdendir. Ayrıca, devletin ekonomi içindeki üretici rolünün hâlâ büyük olması, bir başka deyişle özelleştirmenin hızlandırılmaması, kayıt dışı ekonominin büyüklüğü ve kilit bürokratik kadrolardaki sık değişiklikler enflasyonun yapı taşlarını oluşturmaktadır.⁴²

Gelişmiş ülkelerde %3-5’ in üzerinde bir enflasyon rakamına izin verilmemektedir. Çünkü enflasyonun sadece ekonomik değil; sosyal, politik ve kültürel yönleri vardır. En önemli etkisi gelir ve servet dağılımını değiştirmesidir. Refah, bir sosyal tabakadan diğerine kaymakta, sosyal tepkilere neden olmaktadır. Alternatif yatırım alanlarının cazip hale gelmesiyle gerileyen yatırımlar işsizliğin artmasına neden olmaktadır. Örneğin, faizle para kazanmanın tercih edilmesi gibi. Oluşan belirsiz ortam nedeniyle yabancı sermaye girişi düşük kalmaktadır. Bütçenin açık vermesi sonucu olarak borçlanma giderek artmaktadır. Para basımı ile zaten fazla olan para arzı (piyasada dolaşımda olan para miktarı) artırılmaktadır. Bunun nedeni ise ekonominin katma değer özelliğinin azalmasıdır. Yani kaynak meydana getirilmeden harcamaların sürdürülmeye çalışılması, piyasadaki para miktarının ekonominin fiziksel büyümesinden (gerçek büyüme) daha hızlı artması sonucunu doğurmaktadır.⁴³

Enflasyon aynı zamanda dış ödemeler dengesini (uluslar arası ticari ilişkiler dengesi) olumsuz yönde etkilemektedir. Enflasyon hızı yabancı ülkelere göre fazla olduğunda

⁴¹ Besim Üstünel, Makro Ekonomi, Mısırlı Matbaacılık, 5. Baskı, İstanbul 1990. S. 126

⁴² Muhammet Akdiş. Para Teorisi ve Politikası. Beta Yayıncılık, 1. Baskı, İstanbul, 2001. S.197

⁴³ Akdiş, s.198

devalüasyon yapılmadığı takdirde tüketici, fiyatının aynı ya da daha düşük olması nedeniyle ithal malları tercih etmektedir. Verimlilik ve kalite, spekülasyon (dengesiz anlık gelirler) kazançların daha cazip hale gelmesi nedeniyle düşmektedir. Esnaf ve sanatkarların satmak üzere aldıkları malların, sattıklarından daha hızlı fiyat artışı göstermesi, bu kesimin sattıklarının yerine yenisini koyamamalarına neden olmakta, yani sermaye erimesi oluşmaktadır.⁴⁴

Meslek gurupları açısından bakıldığında en büyük zararı işçiler, emekliler ve memurlar görmektedir. Ticari araçlar ve tüketiciye doğrudan doğruya mal ve hizmet sunanlar en az etkilenenlerdir. Çünkü enflasyonun asıl kurbanları, enflasyon karşısında reel olarak (enflasyon, faiz vs. etkilerden sıyrılmış olarak) gelir kaybeden sabit ve dar gelirlilerdir. Bununla beraber yine araştırmalara göre gelir düzeyi yükseldikçe, enflasyondan olumsuz olarak etkilenme oranı belirgin bir biçimde düşmektedir.⁴⁵

Enflasyonist ortamda tasarruflar büyük oranda dövize çevrilerek saklanmaktadır. Bankalar ise, önceki yıllara oranla, ikinci sıraya gerilemiştir.⁴⁶

Enflasyonist ortamdaki önlemlere bakıldığında, aileler ilk tepki olarak tasarruflarını azaltıp tüketimini kısmaktadır. Ancak enflasyonun etkilerini azaltamayan aile harcama kısıntılarına gider. Araştırmalara göre en yüksek kısıntıyı giyim masraflarında yapar. Bunu sırasıyla mutfak, tatil, eğlence ve kitap-gazete vb. harcamalar takip eder. Fazla çalışma ve diğer aile fertlerinin de çalışması başka bir çözüm yoludur. Aile, son olarak da servetin çözülmesi (altın vb. ziynet eşyalarının satılması) ve borç alma yollarına başvurur.⁴⁷

Türkiye’de yirmi yılı aşkın süredir devam eden enflasyon sorunu, son yıllarda yürütülen ekonomik istikrar paketleri ve özelleştirme çalışmaları ile birlikte tek rakamlı hanelere düşürülmüştür. Ekonomik istikrar hareketliliği içerisinde beklenilmedik bir kriz gerek ekonomik gerekse siyasal açıdan yaşanmadığı takdirde gelecek yıllar içinde Türkiye’deki enflasyon oranlarının %5 gibi rakamların altına düşürülmesi hedeflenmektedir.

⁴⁴ Muhammet Akdiş. Para Teorisi ve Politikası. Beta Yayıncılık, 1. Baskı, İstanbul, 2001. S.199

⁴⁵ Akdiş, s.199

⁴⁶ Akdiş, s.199

⁴⁷ Akdiş, s.199

2.6. Türkiye’de ve Dünyada Enflasyonu Tetikleyen Genel Nedenler

Bu bölümde Türkiye’de ve dünyada enflasyona neden olan etkenlere kısaca göz atacağız.

- Döviz kurlarının, enflasyon oranının üstünde artışı fiyat artışlarına sebep olur.
- Kredi faiz oranlarının, enflasyonun çok üstünde olması, maliyetleri yükseltmesinden dolayı yeni fiyat artışlarına yol açar.
- Emisyon ve para arzının hızlı bir şekilde artması enflasyonun habercisi olarak kabul edilir.
- Tekelleşme ve fiyat anlaşmaları fiyatları yükseltir.
- Bütçe açıklarının yüksekliği sonraki dönemlerde fiyatların tırmanışa geçeceğinin işaretidir.
- Hazine bonusu ve devlet tahvili faizlerinin yüksekliği enflasyonu yükseltir.
- Kuraklık nedeniyle tarımsal üretimin düşmesi enflasyonist etki yapar.
- Ekonominin canlı olduğu ve ücretlerin yükseldiği dönemlerde fiyatlar hareketlenir.
- Enflasyonist beklentiler, yeni fiyat artışları üretir.
- Dünya piyasalarında herhangi bir malın fiyatının yükselişi iç piyasaya da yansır.
- İstikrarsızlık ve belirsizlik dönemlerinde fiyat artışları görülür.
- Geri teknoloji maliyetleri yükselterek enflasyonu körükler.
- Enflasyon oranının çok üstünde belirlenen ücret artışları ve yüksek faizler de fiyatları hareketlendirir.
- Yatırımların duraklaması da sonraki dönemlerde arzdaki artışı önleyeceği için fiyatları yükseltir.⁴⁸

2.7. Fiyat Endeksleri (ÜFE ve TÜFE)

Bu bölümde Türkiye’nin ÜFE ve TÜFE rakamlarına göz atmadan önce bu kavramları inceleyelim.

Bir ekonomide fiyatlar genel düzeyindeki gelişmeler fiyat endeksleri yardımıyla bulunur. Ekonomide üretilen ve pazarlanan pek çok sayıdaki mal ve hizmetin fiyatlarının ve fiyatlardaki değişmeyi saptamak kolay değildir. Eğer ekonomide tek bir mal olsaydı yine

⁴⁸ Besim Üstünel, Makro Ekonomi, Mısırlı Matbaacılık, 5. Baskı, İstanbul 1990. S. 129

güçlükler olacaktı. Çünkü bu tek malın nerede ne zaman ve hangi fiyatı dikkate alınacağı önemli bir sorundur. Gerçeği bütün açıklığı ile yakalamak istersek tüm mal ve hizmetlerin fiyatını saptamamız gerekir. Ama böyle bir çalışma olanaksız olduğundan günümüzde basit modeller oluşturma yoluna gidilmektedir. Belli sayıdaki malların belli yerlerdeki fiyatlarının saptanması ile yetinilmektedir. Bu nedenle modelde yer alan mal sayısı arttıkça gerçeğe daha çok yaklaşılır.

Fiyat endekslerinin hesaplanmasında başlangıç yılının tespiti çok önemlidir. Başlangıç yılı enflasyonist ve deflasyonist eğilimlerin olmadığı ekonomik istikrarın bulunduğu bir yıl olmalıdır. Başlangıç yılında modelde yer alan modellerin fiyatları saptanacak ve ağırlıklı ortalamalar hesaplanacak ve yıllık artış ortaya konulacaktır. Modelde yer alan her malın önemi eşit olmadığından ağırlıklı ortalamalar yöntemi kullanılır. Örneğin gazetenin fiyatı bir yılda %50 azalırken; ekmeğin fiyatı %50 artarsa basit ortalama enflasyon artışı sıfırdır. Oysa bu sonuç şaşırtıcıdır. Bu nedenle ağırlıklı ortalamaları esas almak üzere her malın önemini belirten bir katsayı saptanır.

Tüketicilerin yaşam şartlarını tespit için tüketim mallarından hareketler “Tüketici Fiyat Endeksi (TÜFE)” hesaplanır. Buna karşılık üretim sektöründeki fiyat dalgalanmalarını hesaplamak için Üretici Fiyat Endeksi (ÜFE) hesaplanır⁴⁹.

2.7.1. Üretici Fiyat Endeksi (ÜFE)

Toptan eşya fiyatları esas itibarıyla üretici kesimin girdi maliyetlerini ölçmeyi amaçlar. Bu nedenle içinde nihai malların payı düşüktür. Hizmetler sektörde bulunmamaktadır. Buna karşılık temel girdilerin tümü vardır.⁵⁰

Türkiye’de ÜFE dört ana kategoriye bölünmüştür:

- Tarım, Ormancılık, Avcılık ve Balıkçılık
- İmalat Sanayi
- Madencilik ve Taşocakçılığı
- Elektrik, Gaz ve Su

⁴⁹ 27 Ekim 2005 de yayınlanan ve 01.01.2006 tarihinden itibaren uygulamaya konulan bir kararname ile daha önce Toptan Eşya Fiyat Endeksi (TEFE) olarak kullanılan tanımın ismi Üretici Fiyat Endeksi ÜFE olarak değiştirilmiştir.

⁵⁰ Savaş Akad, “TEFE Endeksi”, Sabah Gazetesi, 10 Mart 2002

İlk kalemin (Tarım, Ormancılık, Avcılık ve Balıkçılık) endeksteeki payı %22.2 dir. Üç alt kategorisi vardır: Tarım-Avcılık, Ormancılık-Tomrukçuluk, Balıkçılık-Balık Üretme Çiftlikleri. Tümü özel kesim üretimidir. Yani bu kalemde devlet yoktur.⁵¹

İkinci kalem olan imalat sanayiinin endeksteeki payı %71.1’dir. İçinde 21 ayrı sanayi kolu tanımlanmıştır. Bunlardan birinde özel kesim yoktur ki o da tütün dür. Altısında devlet yoktur geri kalan on dördünde hem devlet hem de özel kesim vardır.⁵²

Üçüncü kalemin (Madencilik ve Taşocakçılığı) endeksteeki payı %2.5’tir. dört alt bölümü vardır: petrol, kömür ve diğer maden cevherleri ve taşocakçılığı. Dördünde de hem devlet hem özel kesim üretim yapmaktadır.⁵³

Son kalemin (Elektrik, Gaz ve Su) endeksteeki payı %4.2’dir. Biri elektrik ve gaz, diğeri su olmak üzere iki alt bölümden oluşmaktadır. Her ikisinde de sadece devlet kesimi vardır özel kesim yoktur.⁵⁴

2.7.2. Tüketici Fiyatları Endeksi (TÜFE)

Tüketici fiyatları endekslerinde en önemli konu endeksi oluşturan mal ve hizmetlerin seçimi ve ağırlıklarının hesaplanmasıdır. Kural olarak bu amaçla kapsamlı bir anket ve araştırma yapılır. Vatandaş açısından hayat pahalılığını ölçen bu endektir ve ülke parasının satın alma gücünü ifade eder.⁵⁵

Hane Halkı Gelir ve Tüketim Harcamaları Anketi uygulamasına 1964 yılında 4 büyük ilde (İstanbul, İzmir, Ankara, Adana) başlanmıştır. Sonra 1968, 1978 ve 1987’de il sayısı artarak bu anket uygulaması tekrar edilmiştir. Her ay değişen sayıda aileye anket uygulanmıştır. Tüketim kalıbı 26000 ailenin harcamalarından elde edilmiştir. Gelir dağılımı araştırmalarında da bu anket kullanılmaktadır.⁵⁶

TÜFE kapsamı şunlardan oluşmaktadır:

- gıda, içki % 31,09
- konut % 25,8

⁵¹ Savaş Akad, “TEFE Endeksi”, Sabah Gazetesi, 10 Mart 2002

⁵² Akad, aynı.

⁵³ Akad, aynı.

⁵⁴ Akad, aynı.

⁵⁵ Savaş Akad, “TÜFE Endeksi”, Sabah Gazetesi, 14 Mart 2002

⁵⁶ Akad, aynı.

• giyim	% 9,71
• ev eşyası	% 9,35
• lokanta	% 3,07
• ulaştırma	%9,3
• eğlence	% 2,95
• sağlık	% 2,76
• eğitim	% 1,59
• diğer	% 4,38

Yukarıda da görüldüğü üzere TÜFE on ana gruptan oluşmaktadır en büyük ağırlık “Gıda, İçki” gurubunundur. Endeksin %31.09’unu oluşturmaktadır. Bu bölümün içinde 130 ayrı kalem halinde 86 civarında mal vardır.⁵⁷

Hemen arkasından konut grubu gelmektedir bu gurubun içerisinde “kira” kalemi de bulunmaktadır. Endeksteeki ağırlığı % 25.8’dir. Tek başına kira %20 tutmaktadır. Gerisi konut bakımı ve elektrik, yakıt ve su harcamalarıdır. Kira kalemi çok önemlidir. Yapılan çalışmalar Türkiye’de ev sahipliği oranının %85’e ulaştığını göstermektedir. Bu nedenle endekse ayrıca “İzafi Kira” kalemi konmuştur. Yani kendi evinde oturanlara da “eğer ödeselerdi” mantığı ile bir kira ödemesi atfedilmektedir.⁵⁸

Üçüncüsü “Giyim” gurubudur. Endeksteeki ağırlığı %9.71’dir. 73 ayrı kalem halinde 158 maldan oluşmaktadır. Hemen arkasından %9.35 ağırlığına sahip “Ev Eşyası” grubu gelmektedir. 67 kalemde 138 ayrı malı kapsamaktadır.⁵⁹

Bu dört grup endeksin %75’ini oluşturmaktadır. Bu oranın %55’i çeşitli mallardan %20’si ise kiradan oluşmaktadır. Endeksin geri kalan %25’i ise “hizmetler” ağırlıklıdır. Diğer ana guruplar da yukarıda görüldüğü gibidir.⁶⁰

TÜFE’de toplam 410 kalemde 747 mal ve hizmet mevcuttur. Bunlardan yaş meyve-sebze dışında kalanlar ayın 10. ve 20. günlerinde iki defa alınmaktadır. Yaş meyve-sebze ise her hafta yani ayda 4 defa toplanmaktadır. Fiyatlar 6390 işyerinden toplanmaktadır. Örneğin “Gıda” grubu için fiyat alınan işyeri sayısı 1223’tür. Her mal ve hizmet için türüne göre, ne kadarının büyük işyerlerinden ne kadarının da küçük iş yerlerinden alınacağı da

⁵⁷ Savaş Akad, “TÜFE Endeksi”, Sabah Gazetesi, 14 Mart 2002

⁵⁸ Akad, aynı.

⁵⁹ Akad, aynı.

⁶⁰ Akad, aynı.

ayrıca belirlenmektedir. Görüldüğü gibi TÜFE, son derece kapsamlı bir çalışma sonucunda hesaplanmaktadır.⁶¹

Bütün bu çalışmalara karşın bu her iki fiyat endekslerinin yetersizlikleri bulunmaktadır. Bunları şöyle sıralamak mümkündür:

- Fiyat endeksleri belli bir örneğe ve basitleştirmeye dayanır.
- Üretim yapısı ve yeni mallar her zaman dikkate alınmaz.
- Hangi malın modele alınacağıının tespiti zordur.
- Endeksler malların kalite gelişmesini yansıtmaz.
- İstatistiki araştırmalar güçlükler doğurur.

Fiyat endekslerinin anlamı ve değeri bu gözlemlerin ışığı altında düşünülmelidir.

2.8. Enflasyon Oranı

Fiyatlar genel düzeyi ya da paranın değeri sabit olsaydı nominal milli gelir reel milli gelire eşit olurdu. Oysa, enflasyon ve deflasyonun etkisini yaşarız. Fiyatlar genel düzeyindeki sürekli artışa enflasyon denir. Enflasyon oranı fiyat endeksleri yardımıyla hesaplanır. Fiyat endekslerinde başlangıç yılının fiyatlar düzeyi 100 ile ifade edildiğinden sonraki yılların fiyatlarında tek tek saptanarak sonuç bulunur. Örneğin 1. yıl fiyatları 130 olmuş ise, enflasyon oranı %30'dur.⁶²

Bu açıklamalara göre enflasyon oranı şu formülle bulunur.⁶³

$$\text{Enflasyon Oranı} = \frac{(\text{t}) \text{ Yılı F. Endeksi} - (\text{t-1}) \text{ Yılı F. Endeksi}}{(\text{t-1}) \text{ Yılı F. Endeksi}} \times 100$$

⁶¹ Savaş Akad, "TÜFE Endeksi", Sabah Gazetesi, 14 Mart 2002

⁶² Cafer Unay, Genel İktisat, Ekin Kitabevi, Bursa 1997. S.156

⁶³ Unay, s.156

3. YAPAY SİNİR AĞLARI (YSA)

Bu bölüm, çalışmanın temel konusunu oluşturan Yapay Sinir Ağları teknolojisine ait temel ve teorik bilgileri kapsamaktadır. Teknolojik gelişmenin önemli boyutlara ulaştığı günümüzde, insanoğlunun kendisini tanımaya yönelik çalışmaları da önemli aşamalar kaydetmiştir. Yapay zeka (artificial intelligence) kavramı ile insanın en önemli özellikleri olan düşünebilme ve öğrenebilme yetenekleri en önemli araştırma konuları durumuna gelmiştir. Özellikle son zamanlarda bilgisayar kullanımının hızla yaygınlaşması sonucunda yapay zeka çalışmaları da bir ivme kazanmıştır.

İnsanın düşünme yapısını anlamak ve bunun benzerini ortaya çıkaracak bilgisayar işlemlerini geliştirmeye çalışmak olarak tanımlanan yapay zeka, aslında programlanmış bilgisayarlara düşünme yeteneği sağlama girişimidir. İnsan gibi düşünen ve davranan sistemlerin geliştirilmesine yönelik olarak 1950’li yıllardan beri süren yapay zeka çalışmaları, bir noktada insanı taklit etmeye yönelik olduğundan mühendislik, nöroloji ve psikoloji gibi alanlara da yayılmıştır. İnsan gibi düşünebilen ve davranabilen sistemlerin geliştirilmesi için yapılan çalışmalarda bugün gelinen nokta, henüz yapay zekanın tam olarak geliştirilememiş olmasıdır. Yapay zekanın mümkün olabilirliği tartışmaları bir yana bırakılırsa bu konudaki çalışmalar bu alanı destekleyen farklı alanlardaki çalışmalarla birlikte devam etmektedir.

Yapay zeka çalışmaları kapsamında ortaya çıkan ve bir noktada yapay zeka çalışmalarına destek sağlamakta olan farklı alanlardan bir tanesi de Yapay Sinir Ağları teknolojisidir. Dolayısıyla, yapay zeka alanının bir alt dalını oluşturan YSA teknolojisi öğrenebilen sistemlerin temelini oluşturmaktadır. İnsan beyninin temel işlem elemanı olan nöronu (neuron) şekilsel ve işlevsel olarak basit bir şekilde taklit eden YSA’lar, bu yolla biyolojik sinir sisteminin basit bir simülasyonu için oluşturulan programlardır. Bu şekilde, insanoğluna özgü deneyerek (yaşayarak) öğrenme yeteneğini bilgisayar ortamına taşıyabildiği düşünülen YSA teknolojisi bir bilgisayar sistemine inanılmaz bir “girdi veriden öğrenme” kapasitesi sağlamaktadır ve bir çok avantajlar sunmaktadır. Çeşitli avantajlar sunan ve gün geçtikçe gelişen bu teknoloji, günümüzde bir çok alanda olduğu gibi ekonomi ve istatistik alanlarında da faydalanılmaktadır. Özellikle, “Evrensel Fonksiyon Yakınsayıcı Yöntem (Universal Function Approximators)” olarak

tanınmalarından dolayı tahmin ve öngörü gibi verinin içerdiği yapının tanımlanmasını gerektiren alanlarda sıkça kullanılmaktadırlar.

Bu bölümde, YSA hakkında temel ve teorik bilgilere yer verilmiştir. Bundan sonraki kısım olan Bölüm 3.1’de YSA’ların tanımına yer verilmekte ve daha sonraki bölümde YSA’ların mimarisi (yapısı) ve temel elemanları ayrıntılı şekilde anlatılmaktadır. Bölüm 3.3’te YSA çeşitleri anlatılmakta ve çalışmada kullanılan YSA çeşidi olan Geri Yayılmalı İleri Besleme Ağlar ayrıntılı olarak tanıtılmaktadır. Bölüm 3.4’te YSA’ların sağladığı avantajlara değinildikten sonra Bölüm 3.5 içerisinde YSA teknolojisinin tarihsel gelişimi sunulmaktadır. Son olarak, Bölüm 3.6’da Yapay Sinir Ağları ile İstatistik ve Ekonomi alanları arasındaki bağlantılara yer verilmektedir.

3.1. YSA Nedir?

İnsanlığın doğayı araştırma ve taklit etme çabalarının en son ürünlerinden bir tanesi Yapay Sinir Ağları teknolojisidir. Yapay Sinir Ağları, basit biyolojik sinir sisteminin çalışma şeklini simüle etmek için tasarlanan programlardır. Simüle edilen sinir hücreleri (nöronlar) içerirler ve bu nöronlar çeşitli şekillerde birbirlerine bağlanarak ağı oluştururlar. Bu ağlar öğrenme, hafızaya alma ve veriler arasındaki ilişkiyi ortaya çıkarma kapasitesine sahiptirler. Diğer bir ifadeyle, YSA’lar, normalde bir insanın düşünme ve gözlemlemeye yönelik doğal yeteneklerini gerektiren problemlere çözüm üretmektedir. Bir insanın, düşünme ve gözleme yeteneklerini gerektiren problemlere yönelik çözümler üretebilmesinin temel sebebi ise insan beyninin ve dolayısıyla insanın sahip olduğu yaşayarak veya deneyerek öğrenme yeteneğidir.⁶⁴

Biyolojik sistemlerde öğrenme, nöronlar arasındaki sinaptik (synaptic) bağlantıların ayarlanması ile olur. Yani, insanlar doğumlarından itibaren bir “yaşayarak öğrenme” süreci içerisine girerler. Bu süreç içinde beyin sürekli bir gelişme göstermektedir. Yaşayıp tecrübe ettikçe sinaptik bağlantılar ayarlanır ve hatta yeni bağlantılar oluşur. Bu sayede öğrenme gerçekleşir. Bu durum YSA için de geçerlidir. Öğrenme, eğitime yoluyla örnekler kullanarak olur; başka bir deyişle, gerçekleşme girdi/çıkı verilerinin işlenmesiyle, yani eğitime algoritmasının bu verileri kullanarak

⁶⁴ Şakir Kocabaş, Yapay Zeka Ders Notları, İstanbul Teknik Üniversitesi, 1998-1999.

bağlantı ağırlıklarını (weights of the synapses) bir yakınsama sağlanana kadar, tekrar tekrar ayarlamasıyla olur.⁶⁵

YSA'lar, ağırlıklandırılmış şekilde birbirlerine bağlanmış bir çok işlem elemanlarından (nöronlar) oluşan matematiksel sistemlerdir. Bir işlem elemanı, aslında sık sık transfer fonksiyonu olarak anılan bir denklemdir. Bu işlem elemanı, diğer nöronlardan sinyalleri alır; bunları birleştirir, dönüştürür ve sayısal bir sonuç ortaya çıkartır. Genelde, işlem elemanları kabaca gerçek nöronlara karşılık gelirler ve bir ağ içinde birbirlerine bağlanırlar; bu yapı da sinir ağlarını oluşturmaktadır.

Sinirsel (neural) hesaplamanın merkezinde dağıtılmış, adaptif ve doğrusal olmayan işlem kavramları vardır. YSA'lar, geleneksel işlemcilerden farklı şekilde işlem yapmaktadırlar. Geleneksel işlemcilerde, tek bir merkezi işlem elemanı her hareketi sırasıyla gerçekleştirir. YSA'lar ise herbiri büyük bir problemin bir parçası ile ilgilenen, çok sayıda basit işlem elemanlarından oluşmaktadır.⁶⁶ En basit şekilde, bir işlem elemanı, bir girdiyi bir ağırlık kümesi ile ağırlıklandırır, doğrusal olmayan bir şekilde dönüşümünü sağlar ve bir çıktı değeri oluşturur. İlk bakışta, işlem elemanlarının çalışma şekli yanıltıcı şekilde basittir. Sinirsel hesaplamanın gücü, toplam işlem yükünü paylaşan işlem elemanlarının birbirleri arasındaki yoğun bağlantı yapısından gelmektedir.

Çoğu YSA'da, benzer karakteristiğe sahip nöronlar tabakalar halinde yapılandırılırlar ve transfer fonksiyonları eş zamanlı olarak çalıştırılırlar. Hemen hemen tüm ağlar, veri alan nöronlara ve çıktı üreten nöronlara sahiptirler.

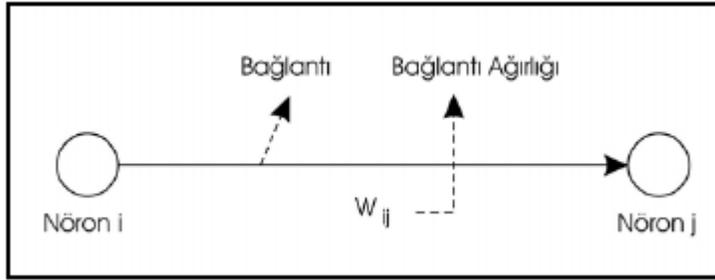
YSA'nın ana ögesi olan matematiksel fonksiyon, ağın mimarisi tarafından şekillendirilir. Daha açık bir şekilde ifade etmek gerekirse, fonksiyonun temel yapısını ağırlıkların büyüklüğü ve işlem elemanlarının işlem şekli belirler. YSA'ların davranışları, yani girdi veriyi çıktı veriye nasıl ilişkilendirdikleri, ilk olarak nöronların transfer fonksiyonlarından, nasıl birbirlerine bağlandıklarından ve bu bağlantıların ağırlıklarından etkilenir.

Bu bilgiler ışığında bakıldığında, YSA'ların yapısı üç ana eleman içermektedir ve Şekil 3.1'deki gibidir. Şekilden de görülebileceği gibi, YSA'ların yapısını oluşturan üç

⁶⁵ DARPA, Neural Network Study. 2004. S.21

⁶⁶ J. M. Zurada, Introduction to Artificial Neural Systems, West St. Paul. 2005. S.36

ana eleman temel işlem elemanı olan nöron, girdi ve çıktı yolunu sağlayan bağlantı ve bu bağlantıların sağlamlığını gösteren bağlantı ağırlığıdır.



Şekil 3.1: YSA Mimarisinin Temel Elemanları

(Hasan Yurtoğlu “Yapay Sinir Ağları ile Öngörü Modellenmesi.” Uzmanlık Tezi, DPT 2005. S.6)

Genel olarak YSA metodolojisinin uygulama adımlarına bakıldığında, YSA'nın basit ama yoğun yapısı ve bazı temel özellikleri daha açık anlaşılabilir. Tipik olarak, bir YSA'nın mimarisi (veya yapısı) oluşturulur ve çeşitli matematiksel algoritmalarla bir tanesi kullanılarak üretilen çıktılarının doğruluk (accuracy) düzeyinin maksimize edilmesi için gerekli olan ağırlık değerleri belirlenir.⁶⁷ YSA'lar önceki örnekleri kullanarak ağırlıkları belirlemek yoluyla girdi değişkenleri ile tahmin edilen değişkenler arasındaki ilişkiyi ortaya çıkartırlar; diğer bir deyişle YSA'lar eğitilir. Bir kez bu ilişkiler ortaya çıkartıldıktan sonra (yani ağ eğitildikten sonra), YSA yeni verilerle çalıştırılabilir ve tahminler üretilebilir. Bir ağın performansı, amaçlanan sinyal ve hata kriteri ile ölçülür. Ağın çıktısı, amaçlanan çıktı ile karşılaştırılarak hata payı elde edilir. Geri Yayılma (backpropagation) olarak adlandırılan bir algoritma hata payını azaltacak şekilde ağırlıkları ayarlamak için kullanılır. Bu işlem defalarca tekrar edilerek ağ eğitilir. Eğitme işleminin amacı performans ölçümleri bazında optimum çözüme ulaşmaktır.⁶⁸

Bağlantısız Mimariler (Connectionist Architectures), Adaptif Sistemler (Adaptive Systems) veya Paralel Dağıtılmış İşlemciler (Parallel Distributed Processing) olarak da adlandırılan YSA'lar, oldukça fazla bağlantı içeren ve paralel yapılandırılmış beyin işlevinden esinlenen bir bilgi işlem paradigmasıdır. Farklı isimlerle anılmaları, farklılık sağlayan bazı temel özelliklerinden kaynaklanmaktadır. Bağlantısız Mimari

⁶⁷Hasan Yurtoğlu, “Yapay Sinir Ağları ile Öngörü Modellenmesi.” Uzmanlık Tezi, DPT 2005. S.6

⁶⁸ Yurtoğlu, s.7

(veya Bağlantısal Sistem) olarak anılmalarının temel sebebi, bireysel işlem elemanları (processing nodes) arasındaki bağlantılardır. Ayrıca, bu bağlantıların ağırlıkları değişebildiğinden YSA'lar çalışma sistemlerini daha da etkinleştirebilmektedirler ve bu yüzden Adaptif Sistem olarak da adlandırılmaktadırlar. Paralel Dağıtılmış İşlemciler olarak adlandırılmalarının sebebi ise ağ içinde çok sayıdaki nod (node) veya nöronların hepsinin birbirlerine paralel olarak çalışmalarıdır. Bu yapı, eşanlı bir çözüm üretebilme yeteneği sağlamaktadır.⁶⁹

YSA paradigması için anahtar özellik, içerdiği bilgi işleme sisteminin yoğun (komplike) yapısıdır. Bu yapı nöronlara karşılık gelen, oldukça fazla sayıda ve sık bir şekilde birbirleri ile bağlantılı işlem elemanları içermektedir. Bu sık bağlantılar ise, sinapslara (synapses) karşılık gelen ağırlıklı bağlantılar ile sağlanmaktadır.⁷⁰

Yapay Sinir Ağları hakkında buraya kadar sunulan bilgiler YSA'ların ne olduğu hakkında genel bir bilgi sağlamaktadır. Bununla beraber YSA'lar için genel bir tanım vermek de faydalı olacaktır. Yapay Sinir Ağları için üzerinde fikir birliği sağlanmış tek bir tanım yoktur. Geniş ya da dar kapsamda bir çok tanımla karşılaşılabilir. Hatta, bazı araştırmacılar YSA için genel bir tanım vermek yerine, YSA türlerinin kendi içinde tanımlanması gerektiğini savunmaktadır. Bununla birlikte, bütünlüğü sağlamak amacıyla çeşitli kapsamlarda bazı genel tanımlara bu bölümde yer verilmektedir.

Tanım 1:

Yapay Sinir Ağları, en kısa ve basit şekilde, bir örnekler kümesi yardımıyla parametrelerin uyarlanabilmesini sağlayacak bir matematiksel formül için yazılan bilgisayar programı olarak tanımlanabilir. Bu tanım, YSA'yı en basit şekilde ve teknik detaya girilmeksizin ifade etmektedir.⁷¹

Tanım 2:

Yine basit ama daha teknik ikinci bir tanım ise şu şekildedir: YSA, ilgili bağlantı ağırlıklarıyla (synaptic weights) bir ağa bağlanmış basit işlem elemanlarından (nöron) oluşan bir sistemdir.⁷²

⁶⁹ Hasan Yurtoğlu, "Yapay Sinir Ağları ile Öngörü Modellenmesi." Uzmanlık Tezi, DPT 2005. S.7

⁷⁰ Yurtoğlu, S.7

⁷¹ G. McNail ve D. Anderson. "Artificial Neural Networks Technology", Data & Analysis Center for Software, 1992. S.4

⁷² McNail & Anderson, s.4

Tanım 3:

“DARPA Neural Network Study (1988)” isimli yayında ise biraz daha açıklayıcı bir tanım kullanılmaktadır:

“Bir YSA, birbirlerine paralel olarak çalışan bir çok basit işlem elemanından oluşan ve fonksiyonu, ağı yapısı, bağlantı ağırlıkları ve elemanlarda gerçekleştirilen işlemler tarafından belirlenen bir sistemdir.”⁷³

Tanım 4:

Daha kapsamlı ve genel kabul gören bir tanım ise Haykin (1999) tarafından verilmektedir:

“Bir sinir ağı, basit işlem birimlerinden oluşan, deneyimsel bilgileri biriktirmeye yönelik doğal bir eğilimi olan ve bunların kullanılmasını sağlayan yoğun bir şekilde paralel dağıtılmış bir işlemcidir. Bu işlemci iki şekilde beyin ile benzerlik göstermektedir:

1. Bilgi, ağ tarafından bir öğrenme süreciyle çevreden elde edilir.
2. Elde edilen bilgileri biriktirmek için sinaptik ağırlıklar olarak da bilinen nöronlar arası bağlantı güçleri kullanılır.”⁷⁴

YSA’lar gerçek hayatta karşılaşılan problemlerde oldukça geniş bir uygulama alanı kazanmışlardır. Bugün, bir çok endüstride başarılı şekilde kullanılmaktadırlar. Uygulama alanları için bir sınır yoktur fakat, öngörü, modelleme ve sınıflandırma gibi bazı alanlarda ağırlıklı olarak kullanılmaktadır. YSA’lar 1950’li yıllarda ortaya çıkmalarına rağmen, ancak 1980’li yılların ortalarında genel amaçlı kullanım için yeterli seviyeye gelmişlerdir. Bugün, YSA’lar bir çok ciddi problem üzerinde uygulanmaktadır ve bu problemlerin sayısı giderek artmaktadır. Verideki trend veya yapıyı (pattern) en iyi tanımlayan yöntem olmaları dolayısıyla, tahmin (prediction) ve öngörü işlemleri için çok uygundur. YSA’ların gerçek hayattaki yaygın uygulama alanlarına şu örnekler verilebilir⁷⁵:

- Kalite Kontrol
- Finansal Öngörü
- Ekonomik Öngörü

⁷³ DARPA, “Neural Network Study”, 2004. S.15

⁷⁴ Bu tanım, Haykin (1999)’dan alınmıştır. Fakat kaynakta, Alexander ve Morton (1990)’dan alıntı olduğu belirtilmektedir.

⁷⁵ Uygulama alanlarının listesi daha uzatılabilir çünkü YSA’lar artık hemen hemen her alana girmiş bulunmaktadır. Burada, önemli görülen bazı alanlar seçilerek listelenmiştir.

- Kredi Derecelendirme
- Konuşma ve Yapı Tanımlama
- İşlem Modelleme ve Yönetimi
- Laboratuvar Araştırmaları
- İflas Tahmini
- Petrol ve Gaz Arama

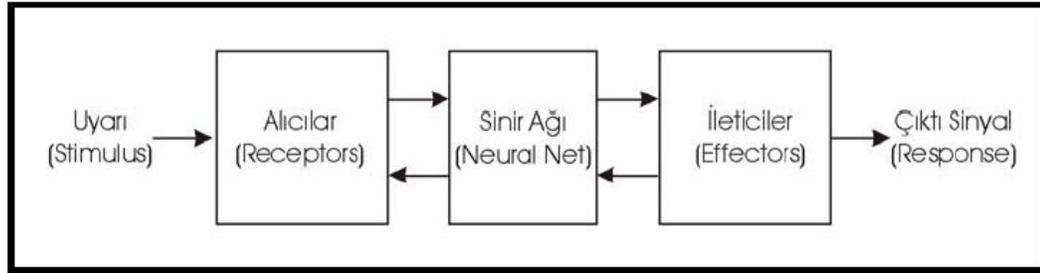
YSA'lar, tanımlanmamış girdi veriler hakkında karar verirken genelleme yapabildikleri için iyi birer yapı tanımlayıcısı (pattern recognition engine) ve sağlam sınıflandırıcıdır (robust classifier). Fonksiyonel tahmin (prediction) ve sistem modelleme gibi fiziksel işlemin anlaşılmadığı veya aşırı karmaşık olduğu problemler yanında konuşma, karakter ve sinyal tanımlama gibi çeşitli sınıflandırma problemleri için çözüm yolları sağlamaktadırlar. Ayrıca, kontrol problemlerinde de uygulama sahası bulmaktadırlar.

YSA'lar yoğun bağlantılı ve komplike işlem yapıları nedeniyle çalışabilecekleri özel ortamlara ihtiyaç duymaktadırlar. Bu yüzden, YSA'lar, bu amaca yönelik olarak hazırlanmış özel yazılımlar ile bilgisayarlarda çalıştırılmaktadırlar. Günümüzde ise, gittikçe artan oranda yoğun ve karmaşık sinir ağlarını çalıştırabilmek ve daha hızlı işlem yapabilmek için özel donanımlar geliştirilmektedir.

3.2. YSA'nın Yapısı: Elemanları ve Mimarisi

Önceden de belirtildiği gibi, yapay sinir ağları insan beyninden esinlenilmiş yapılardır. Bu yüzden, YSA'ların yapısını anlamak için insan beyninin yapısını ve çalışma şeklini anlamak önemlidir. Bununla birlikte, tahmin edilebileceği gibi insan beyni, karmaşık yapısı ile anlaşılması ve anlatılması zor bir konudur. Hatta, beynin çalışma şekli hala tam olarak anlaşılmamıştır. Çok farklı bir disiplinin konusu olan bu temanın burada açıklanması gereksiz kalmaktadır. Ancak, en azından konunun özünün anlaşılabilmesi açısından bazı yararlı bilgiler verilebileceği düşüncesi ile genel bir açıklama yapılmaktadır.

İnsan beyni, sinir sisteminin merkezini oluşturan temel elemandır. En basit şekilde, sürekli olarak iletilen bilgiyi alır, idrak eder (işler) ve uygun kararları vererek gerekli yerlere iletir. Çok basit görünmekle birlikte aslında oldukça karmaşık olan bu yapının Haykin (1999) tarafından kullanılan basit bir gösterimi Şekil 3.2'de sunulmaktadır.



Şekil 3.2: Sinir Sisteminin Blok Diyagramı

(S. Haykin. Neural Networks A Comprehensive Foundation. Prentice Hall International Inc. 1999. S.41)

S.41)

Şekilden takip edilebileceği gibi, dışarıdan veya başka bir organdan gelen sinyaller (uyarı) alıcılar yoluyla sinir ağına iletilir. Sinyaller burada işlemde geçirilerek çıktı sinyaller oluşturulur. Oluşturulan çıktı sinyaller ise ileticiler yoluyla dış ortama veya diğer organlara iletilirler. Şekil 3.2’de Sinir Ağı olarak gösterilen ortadaki bölüm, yani beyin, sinir sisteminin merkezi konumundadır. Beynin temel yapı taşları ise sinir hücreleri, diğer bir ifadeyle nöronlardır (bkz. Cajal, 1911). Beyin, işlevini birbirleri arasında yoğun bağlantılar bulunan bu yapı taşları ile yerine getirir. Nöronların en belirgin özelliği, vücudun diğer bölümlerinin tersine yeniden üretilmeyen belirli bir hücre türü olmasıdır. Beynin diğer temel yapısal ve fonksiyonel birimleri olan bağlantılar (synapses) nöronlar arası etkileşimi sağlarlar. Dolayısıyla, beyin yapısında bu bağlantılar da önemli bir yer tutmaktadır. Zaten beyin oldukça etkin çalışan bir organ olmasının temel sebebi de bu yoğun bağlantılı yapısıdır. Bu yapı sayesinde beyin, bugünkü bilgisayar teknolojisinden kat kat daha etkin bir şekilde çalışabilmektedir.

Beynin bu yapısı etkinlik açısından olduğu kadar bir diğer önemli özellik açısından önem taşımaktadır. Bu yoğun bağlantılı yapı beyin plastiklik (yenilenebilme) özelliğini de beraberinde getirmektedir. Plastiklik özelliği, gelişmekte olan sinir sisteminin kendisini kuşatan çevreye adapte olmasını sağlamaktadır. Gelişmiş bir beyinde, plastiklik iki mekanizma ile izah edilebilmektedir. Bunlar, nöronlar arasında yeni bağlantıların oluşturulması ve var olan bağlantıların modifiye edilmesidir. Ayrıca, bu özellik öğrenme kavramı açısından da çok büyük önem taşımaktadır.⁷⁶

⁷⁶ S. Haykin. Neural Networks A Comprehensive Foundation. Prentice Hall International Inc. 1999. S.42

Plastikliğin, nöronların işlem yapabilmeleri için gerekli bir özellik olduğu görülmektedir. Çünkü, öğrenme süreci bağlantı ağırlıklarının değiştirilmesi veya yeni bağlantıların oluşturulması (hatta bazı bağlantıların iptal edilmesi) sayesinde gerçekleşmektedir. Bu ilişki, yapay nöronlar kullanarak beyinden esinlenilmiş sinir ağları oluşturulabilmesini sağlamaktadır.

Yapay Sinir Ağları, beyinden esinlenildiklerinden dolayı benzer yapıya sahiptirler. Fakat, beynin yoğun bağlantılı ve komplike yapısının sadece beyine özel bir özellik olduğu belirtilmelidir. Başka hiçbir yerde veya dijital bilgisayarda bulunmayan bu yapıya yakınsamak günümüz teknolojisine bile çok uzaktır. Yapay sinir ağlarını oluşturmak için kullanılan yapay nöronlar, beyindekilere kıyasla oldukça ilkel sayılırlar. Dolayısıyla, yapay nöronlar beynin yoğun bağlantılı ve komplike yapısından hala oldukça uzaktırlar ama genel yapı olarak tutarlıdırlar. Diğer bir ifadeyle, YSA'lar, komplike, çok yönlü ve güçlü bir organizma olan beynin sadece en temel elemanlarını kopyalamaya çalışmaktadır.

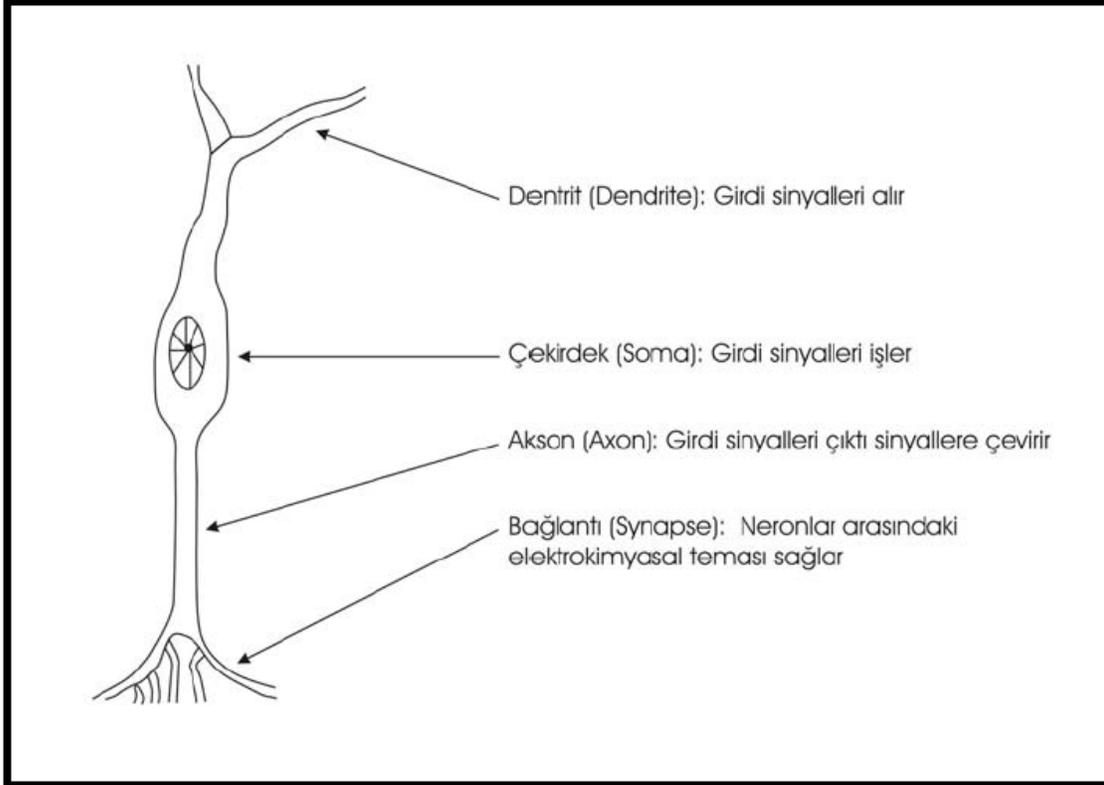
Yapay Nöron

Yapay sinir ağlarının genel yapı olarak beyinden esinlendiği daha önce belirtilmişti. Doğal olarak, YSA'ların temel elemanları da yapay nöronlardır (bundan sonra yapay nöron yerine sadece nöron kelimesi kullanılmaktadır). Bu nöronlar, aralarındaki bağlantılar oluşturularak ve tabakalar halinde gruplandırılarak yapay sinir ağları oluşturulmaktadır.

İnsanın beyinsel gücünün bu yapı taşları birkaç genel işleve sahiptirler. Bir biyolojik nöron, temel olarak, diğer kaynaklardan girdiler alır, belirli bir şekilde bunları birleştirir, sonuç üzerinde bir işlem (genelde doğrusal olmayan) uygular ve nihai sonucu üretir. Şekil 3.3 bir nöronun dört temel elemandan oluşan genel yapısını ve bu dört eleman arasındaki ilişkiyi göstermektedir.

Şekilden de görüldüğü gibi, tüm doğal nöronlar dört temel bileşene sahiptir. Bu bileşenler biyolojik isimleri ile bilinirler: dentrit (dendrite), çekirdek (soma), akson (axon) ve bağlantı veya sinaps (synapse). Dentritler, çekirdeğin saça benzeyen uzantılarıdır ve girdi kanalları olarak işlev görürler. Bu girdi kanalları diğer nöronların sinapsları aracılığıyla girdilerini alırlar. Daha sonra çekirdek, gelen bu sinyalleri zaman içinde işler.

Çekirdek, bu işlenmiş değeri bir çıktıya dönüştürdükten sonra bu çıktıyı akson ve sinapslar aracılığıyla diğer nöronlara gönderir.



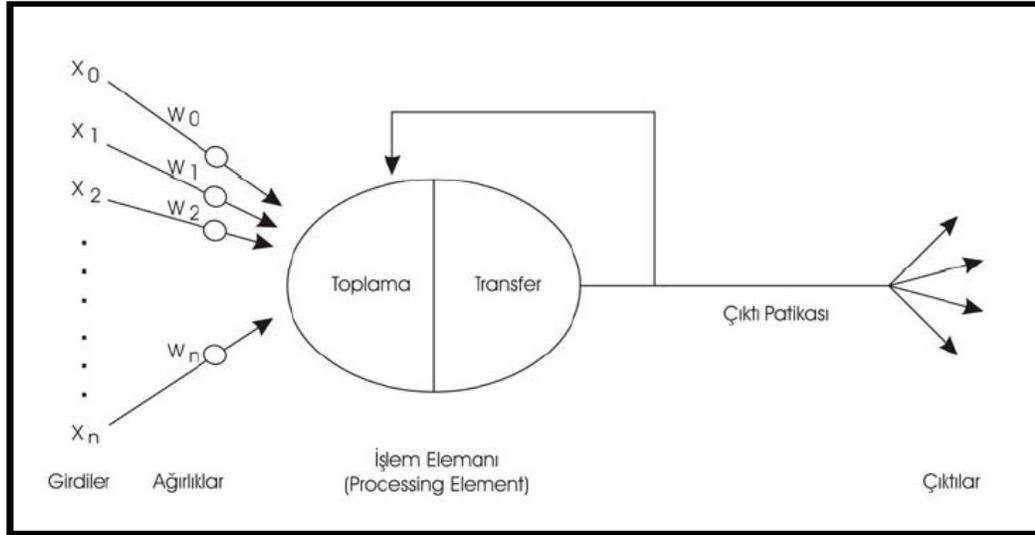
Şekil 3.3: Biyolojik Nöronun Genel Yapısı ve İşlevleri

(S. Haykin. Neural Networks A Comprehensive Foundation. Prentice Hall International Inc. 1999.

S.43)

Yapay sinir ağlarının temel işlem elemanı olan yapay nöronlar, doğal nöronların dört temel fonksiyonunu simüle ederler. Bir yapay nöronun temel yapısı, genel haliyle, Şekil 3.4'te sunulmaktadır. Şekil 3.4'te girdi değerler $x(i)$ matematiksel sembolü ile gösterilmiştir ve bu gösterimde $i = 0,1,2,\dots,n$ değerlerini almaktadır. Bu girdi değerlerin her biri bir bağlantı ağırlığıyla çarpılmaktadır. Bu ağırlıklar ise $w(i)$ ile gösterilmektedir. En basit yapıda, bu çarpımlar toplanır ve bir transfer fonksiyonuna gönderilerek sonuç üretilir. Bu sonuç daha sonra bir çıktıya dönüştürülür. Bu elektronik uygulama değişik toplama fonksiyonları ve transfer fonksiyonları kullanabilir ve farklı ağ yapılarında uygulanabilir.⁷⁷

⁷⁷ Hasan Yurtoğlu, "Yapay Sinir Ağları ile Öngörü Modellenmesi." Uzmanlık Tezi, DPT 2005. S.14



Şekil 3.4: Yapay Nöronun Genel Yapısı

(Hasan Yurtoğlu, "Yapay Sinir Ağları ile Öngörü Modellenmesi." Uzmanlık Tezi, DPT 2005. S.7)

Şekil 3.4 McCulloch ve Pitts (1943) tarafından tanımlanan, biyolojik nöronun basit matematiksel modelinin gösterimi olarak da düşünülebilir. McCulloch-Pitts modeli incelendiğinde, toplama fonksiyonu olarak doğrusal bir fonksiyon ve transfer fonksiyonu olarak birim adım fonksiyonu kullanılmış olduğu görülmektedir. Temelde biyolojik nörona benzer bir şekilde, işlem elemanı toplama fonksiyonu sonucunun belirli bir eşik değerinin altında veya üstünde olmasına göre çıktısını iki ihtimal arasından seçerek oluşturmaktadır. Bu matematiksel modelin fonksiyonel gösterimi aşağıdaki gibidir.⁷⁸

$$y_i = \Psi(g(x)) = \Psi\left(\sum_{j=0}^n w_{ij} x_j - Q_i\right) ; x_i = (x_0, x_1, \dots, x_n) \in \mathfrak{R} \quad (1)$$

Bu gösterimde, y_i çıktı değeri, $\Psi(\cdot)$ transfer fonksiyonunu, $g(\cdot)$ toplama fonksiyonunu, w_{ij} bağlantı ağırlıklarını ve Q_i ise i nolu nöron için eşik değerini göstermektedir. $\Psi(\cdot)$ transfer fonksiyonu birim adım fonksiyonudur:⁷⁹

$$\Psi(\cdot) = \begin{cases} 1 ; g(\cdot) \geq 0 \\ 0 ; g(\cdot) < 0 \end{cases} \quad (2)$$

⁷⁸ H. Morton & I. Alexander, An Introduction to Neural Computing, Chapman and Hall, London 1990. S. 23

⁷⁹ Morton & Alexander, s.23

$g(.)$ toplama fonksiyonu ise x_j girdilerinin doğrusal bir bileşimi olarak düşünülmüştür:⁸⁰

$$g(.) = \sum_{j=0}^n w_{ij} x_j - Q_i \quad (3)$$

McCulloch-Pitts modelinde transfer fonksiyonu olarak birim adım fonksiyonu ve toplama fonksiyonu olarak doğrusal bir fonksiyon kullanılmakla birlikte YSA alanındaki gelişmelerle beraber farklı fonksiyonların kullanılabilmesi sağlanmıştır. Şekil 3.5 içinde YSA modellerinde kullanılacak farklı fonksiyonlara bazı örnekler sunulmaktadır. Basitçe görülebileceği gibi, hangi fonksiyon kullanılırsa kullanılsın, bir nöron modelinin matematiksel ve fonksiyonel gösterimi değişmeyecektir.

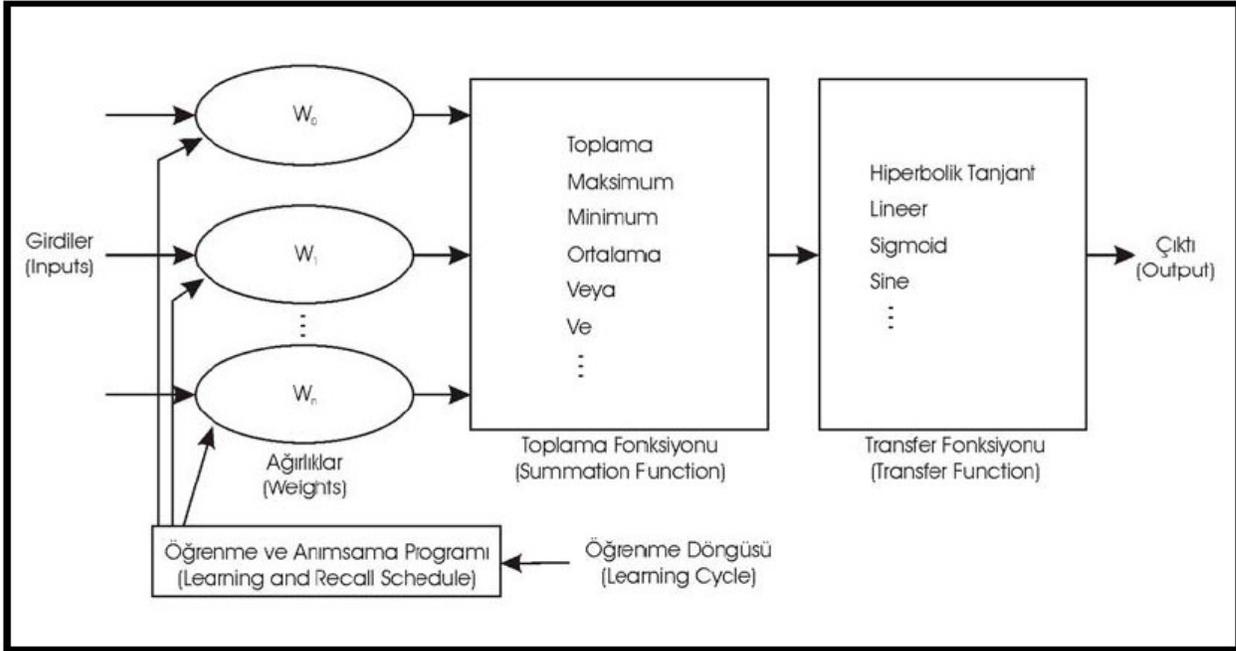
Bu yapıda kullanılan fonksiyonlar temelde uygulama konusuna bağlıdır. Bazı uygulamalar ikili (binary) veri seti gerektirir. Bu uygulamalara örnek olarak konuşma tanımlama ve metin tanıma uygulamaları verilebilir. Bu tür uygulamalar, doğal olarak, sadece toplama fonksiyonu içeren nöronlardan oluşan ağları kullanamaz. Bu ağlar mantıksal fonksiyonları kullanabilir ve bu fonksiyonlar toplama ve transfer fonksiyonlarına dahil edilebilir. Veya bazı uygulamalar basit bir şekilde toplama ve belirli bir eşik değeri ile karşılaştırma şeklinde bir işleme gereksinim duyabilirler. Bu şekilde evet/hayır, doğru/yanlış veya 0/1 gibi iki olası sonuç arasından seçim yapılabilir. Bazı fonksiyonlar ise girdi verileri zamanla ilişkilendirebilir ve bu şekilde zamana bağlı ağlar oluşturulabilir.⁸¹

Şekil 3.5’de, daha önce tanımlanan basit bir yapay nöron yapısının daha detaylı bir şeması sunulmaktadır. Şekilde, girdi değerler işlem elemanına üst sol bölümden girmektedir. İşlemden önce ilk adım, bu girdi değerlerin her birinin ilgili ağırlıklarla $w(i)$ ağırlıklandırılmalarıdır. Bir nöron genellikle, eşanlı olarak birçok sayıda girdi alır. Her girdinin kendi nispi ağırlığı vardır. Bu ağırlıklar, biyolojik nöronların değişen sinaptik etkililikleri ile aynı görevi üstlenirler. Her iki durumda da, bazı girdiler diğerlerine göre daha önemli hale gelirler. Bu sayede, işlem elemanının bir sinirsel tepki üretmesi işleminde daha fazla etkili olurlar. Ayrıca, ağırlıklar girdi sinyalin güçlülüğünü belirleyen

⁸⁰ H. Morton & I. Alexander, An Introduction to Neural Computing, Chapman and Hall, London 1990. S. 23

⁸¹ Hasan Yurtoğlu, “Yapay Sinir Ağları ile Öngörü Modellenmesi.” Uzmanlık Tezi, DPT 2005. S.15-16

adaptif katsayılarıdır. Yani, girdinin bağlantı gücünün bir ölçüsüdür. Bu bağlantı güçleri, çeşitli eğitim setlerine göre değiştirilebilirler.



Şekil 3.5: Yapay Nöronun Detaylı Yapısı

(Hasan Yurtoğlu, “Yapay Sinir Ağları ile Öngörü Modellenmesi.” Uzmanlık Tezi, DPT 2005.

S.16)

Ağırlıklandırmadan sonra, bu değiştirilmiş girdiler toplama fonksiyonuna gönderilirler. Toplama fonksiyonunda, adından da anlaşılacağı gibi, genelde toplama işlemi yapılmaktadır fakat bir çok farklı işlem çeşidi toplama fonksiyonu için kullanılabilir. Toplama fonksiyonu, bu basit çarpımlar toplamına ek olarak, minimum, maksimum, mod, çarpım veya çeşitli normalizasyon işlemlerinden birisi olabilir. Girdileri birleştirecek olan algoritma genellikle seçilen ağ mimarisine de bağlıdır. Bu fonksiyonlar farklı şekilde değerler üretebilir ve sonra bu değerler ileri doğru gönderilir. Ek olarak, uygulamacı kendi fonksiyonunu oluşturup toplama fonksiyonu olarak kullanabilir. Bazı toplama fonksiyonları, transfer fonksiyonuna iletmeye önce, sonuçları üzerinde ilave işlemler yaparlar. Bu işlem aktivasyon fonksiyonu olarak adlandırılan işlemidir. Bir aktivasyon fonksiyonu kullanmanın amacı toplama fonksiyonu çıktısının zamana bağlı olarak değişmesini sağlamaktır. Fakat, aktivasyon fonksiyonu literatürü henüz tam olarak gelişmemiştir. Bundan dolayı, çoğu yapay sinir ağında birim aktivasyon fonksiyonu kullanılmaktadır. Birim aktivasyon fonksiyonu ise bir aktivasyon fonksiyonu

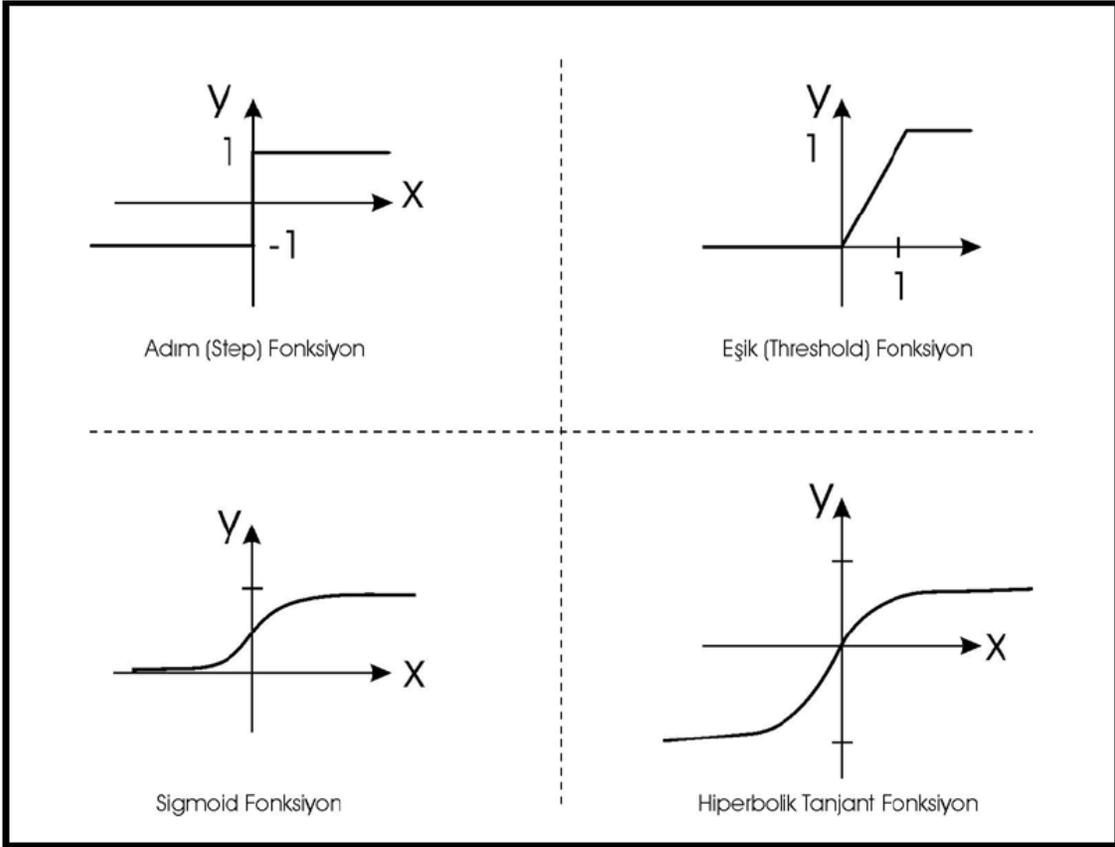
kullanılmaması ile aynı anlama gelmektedir. Ayrıca, aktivasyon fonksiyonu, her işlem birimi için ayrı ayrı kullanılan bir bileşenden ziyade ağıın genel bir bileşenidir. Yani, oluşturulan bir ağ yapısında, tüm işlem elemanları aynı aktivasyon fonksiyonunu kullanırlar.

Sonraki aşamada toplama fonksiyonunun çıktısı transfer fonksiyonuna gönderilir. Bu fonksiyon, aldığı değeri bir algoritma ile gerçek bir çıktıya dönüştürür. Transfer fonksiyonu genellikle doğrusal olmayan bir fonksiyondur. Doğrusal fonksiyonlar genelde tercih edilmez çünkü doğrusal fonksiyonlarda çıktı, girdi ile orantılıdır. Bu durum, ilk YSA denemelerinin başarısızlıkla sonuçlanmasının temel nedenidir.⁸² Genellikle kullanılan transfer fonksiyonları eşik, sigmoid, hiperbolik tanjant vb. fonksiyonlardır. Bu fonksiyonlar arasında en çok kullanılanlar Şekil 3.6’da örneklenmiştir. Transfer fonksiyonunun sonucu genellikle işlem elemanının çıktısıdır. Transfer fonksiyonunun çalışma yapısı Şekil 3.7’de sigmoid fonksiyon kullanılarak örneklenmektedir. Sigmoid transfer fonksiyonu, toplama fonksiyonundan gelen ve şekilde ‘Toplam’ olarak gösterilen değeri alır ve sıfır ile bir arasında bir değere dönüştürür. Sıfır ile bir arasındaki bu değer transfer fonksiyonunun ve dolayısıyla işlem elemanının çıktısıdır ve dış ortama veya girdi olarak başka bir nörona iletilir.

Transfer fonksiyonu işlemi öncesinde, sisteme tekdüze (uniform) dağılmış bir rassal hata eklenebilmektedir. Bu rassal hatanın kaynağı ve büyüklüğü, ağıın öğrenme işlemi sürecinde belirlenir. Sisteme böyle bir hata teriminin eklenmesinin sebebi, insan beyninin işlevinin, içinde bulunduğu ortamın şartlarından (örnek olarak sıcak/soğuk olmasından) etkileniyor olmasıdır. Bu yüzden, YSA literatüründe rassal hata ekleme işlemi “sıcaklık (temperature)” olarak da adlandırılmaktadır. Günümüzde, rassal hata kullanımı fiilen tam olarak yerleşmemiştir ve halen bir araştırma süreci içerisinde. Ayrıca, bazı ağlarda, transfer fonksiyonunun çıktısı üzerinde başka işlemler, ölçeklendirme ve sınırlandırma, yapılabilmektedir.⁸³

⁸² M. L. Minsky ve S. A. Papert. *Perceptrons*, Cambridge, MA: MIT Press. 1969. S.46

⁸³ A. Harvey, *Forecasting, Structural Time Series Models, and the Kalman Filter*, Cambridge: Cambridge University Press. 1989. S.63



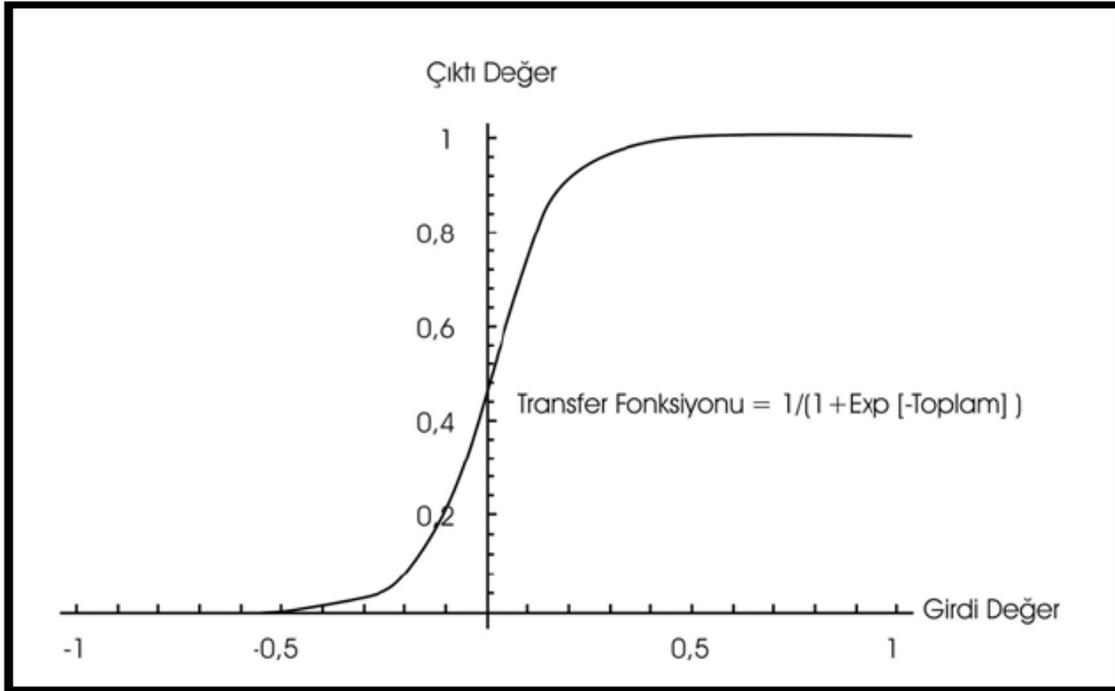
Şekil 3.6: En Çok Kullanılan Transfer Fonksiyonları

(Hasan Yurtoğlu, “Yapay Sinir Ağları ile Öngörü Modellenmesi.” Uzmanlık Tezi, DPT 2005.

S.18)

Transfer fonksiyonundan çıkan değer işlem elemanının da çıktısıdır. Fakat, bazı durumlarda işlem elemanının bu çıktıyı bir çıktı fonksiyonu ile bir dönüşüme uğratması gerekebilmektedir. Bu çıktı, ağın yapısına göre, girdi olarak başka bir işlem elemanına veya bir dış bağlantıya gönderilir. Tüm YSA’lar, yukarıda temel elemanları anlatılan bu temel yapı taşlarından yani nöronlardan oluşturulurlar. Bu yapı taşlarının dizaynı, sinir ağı sanatının, başka bir deyişle mimarisinin oluşturulmasının ilk bölümüdür. Bu sanatın ikinci bölümü ise bu işlem elemanlarının kümelenmesi ve birbirleri arasındaki bağlantıların oluşturulmasını içerir. Beyinde kümelenme, bilginin dinamik, etkileşimli ve kendiliğinden organize bir şekilde işlenmesini sağlayacak şekildedir. Biyolojik sinir ağları üç boyutlu uzayda mikroskobik elemanlarla oluşturulur. Bu nöronlar hemen hemen sınırsız sayıda bağlantılar içerirler. Bu, yapay sinirler için mümkün değildir. Bugünkü

teknoloji ile iki boyutlu ortamda ve belirli sayıda bağlantı içeren nöronlar oluşturulabilmektedir. Bu durum, YSA'ların yetenek ve çeşitlerini sınırlamaktadır.



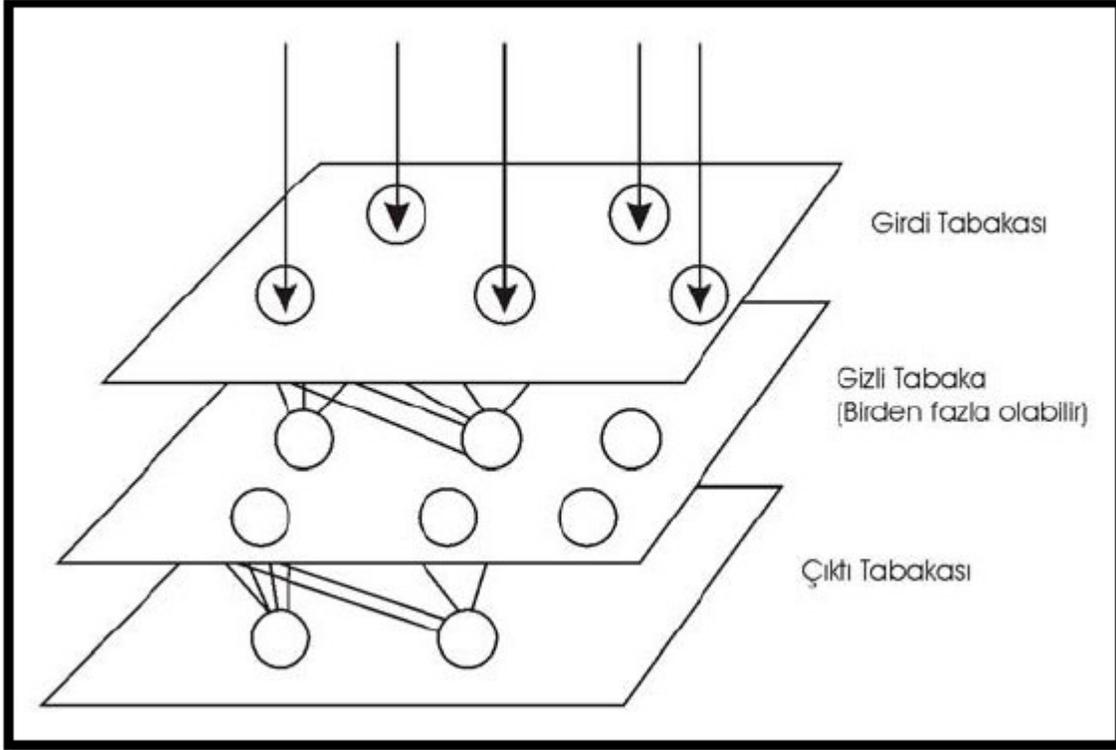
Şekil 3.7: Transfer Fonksiyonunun Çalışma Yapısı

(Hasan Yurtoğlu, "Yapay Sinir Ağları ile Öngörü Modellenmesi." Uzmanlık Tezi, DPT 2005.

S.18)

YSA'larda, yapay nöronlar basit bir şekilde kümelenilmektedirler. Bu kümelenme tabakalar halinde yapılmaktadır ve daha sonra bu tabakalar bir diğerine ilişkilendirilmektedir. Temel olarak, tüm YSA'lar benzer bir yapıya sahiptirler. Böyle bir genel yapı Şekil 3.8'de gösterilmektedir. Bu yapıda, bazı nöronlar girdileri almak için bazı nöronlar ise çıktılarını iletmek için dış mekan ile bağlantılı haldedirler. Geri kalan tüm nöronlar ise gizli tabakalardadırlar, yani sadece ağ içinde bağlantıları vardır.

Önemli olan nokta, bir sinir ağının, bir nöronlar yumağından daha komplike olması gerektiğidir. YSA'ların ilk yıllarında, bazı araştırmacılar, nöronlar arasındaki bağlantıları rassal olarak oluşturmuşlar ve olumsuz sonuçlarla karşılaşmışlardır. Bir yapıyı dizayn etmenin en kolay yolu elemanları tabakalandırmaktır. Burada tabakalandırmanın üç bölümü vardır. Bunlar, nöronları tabakalar halinde gruplandırmak, tabakalar arasındaki bağlantıları gruplandırmak ve son olarak ise toplama ve transfer fonksiyonlarını gruplandırmaktır.



Şekil 3.8: YSA'ların Genel Yapısı

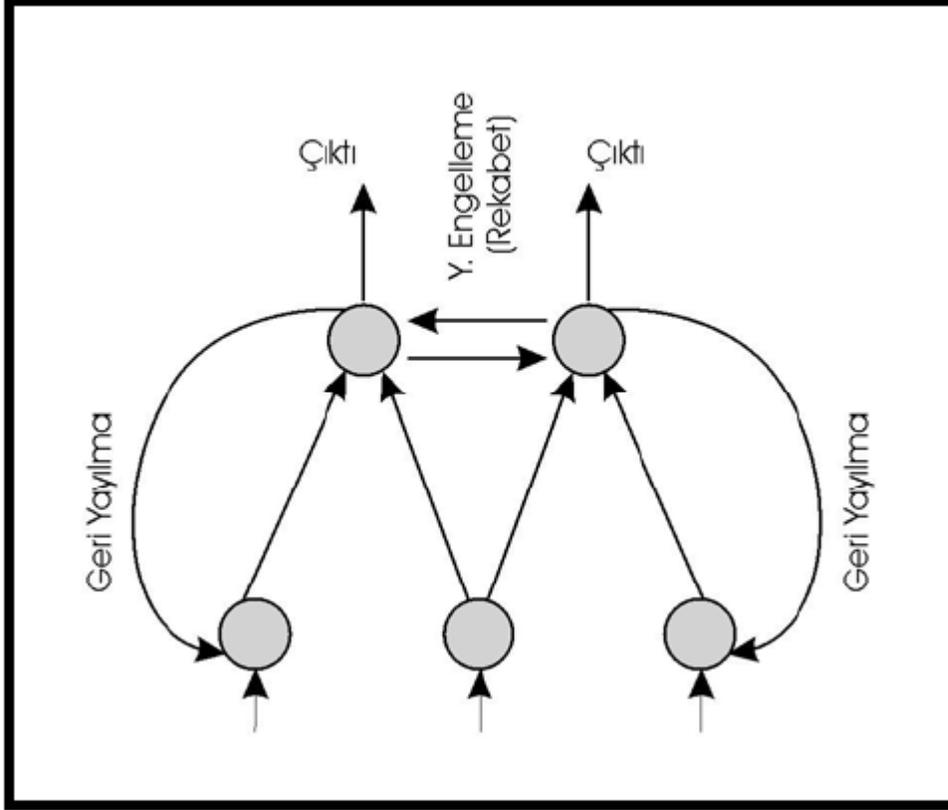
(Hasan Yurtoğlu, "Yapay Sinir Ağları ile Öngörü Modellenmesi." Uzmanlık Tezi, DPT 2005.

S.20)

Tek tabaka ya da tek eleman içeren bazı başarılı ağlar oluşturulabilmesine rağmen çoğu uygulamalar en az üç tabaka (girdi tabakası, gizli tabaka ve çıktı tabakası) içeren ağlara ihtiyaç duymaktadır. Girdi tabakası, dışarıdan girdileri alan nöronları içerir. Ayrıca, önemli olan bir nokta, girdi tabakasındaki nöronların girdi değerler üzerinde bir işlem uygulamamasıdır. Sadece girdi değerleri bir sonraki tabakaya iletirler ve bu yüzden de bazı araştırmacılar tarafından ağların tabaka sayısına dahil edilmezler. Çıktı tabakası ise çıktıları dışarı ileten nöronları içeren tabakadır. Girdi ve çıktı tabakaları tek tabakadan oluşurken bu iki tabaka arasında birden fazla gizli tabaka bulunabilir. Bu gizli tabakalar çok sayıda nöron içerirler ve bu nöronlar tamamen ağ içindeki diğer nöronlarla bağlantılıdır. Çoğu ağ türünde, gizli tabakadaki bir nöron sadece bir önceki tabakanın tüm nöronlarından sinyal alır. Nöron işlemini yaptıktan sonra ise çıktısını bir sonraki tabakanın tüm nöronlarına gönderir. Bu yapı ağın çıktısı için bir ileri besleme patikası oluşturur. Bu bir nöronun diğerine olan iletişim hattı, sinir ağları için önemli bir parçadır.

Bazı ağlarda, bir nöron aynı tabakadaki başka nöronlara engel (inhibit) oluşturabilir. Bu, yanıl engelleme (lateral inhibition) veya rekabet (competition) olarak adlandırılır ve en çok çıktı tabakasında kullanılır.⁸⁴

Diğer bir bağlantı şekli ise geri yayılmadır (feedback). Geri yayılma bağlantı, bir tabakanın çıktısının önceki tabakaya gönderilmesidir ve Şekil 3.9’da yanıl engelleme ve rekabet kavramlarıyla birlikte örneklennmektedir.



Şekil 3.9: Geri Yayılma Bağlantı Yapısı

(Hasan Yurtoğlu, “Yapay Sinir Ağları ile Öngörü Modellenmesi.” Uzmanlık Tezi, DPT 2005.

S.21)

Nöronların diğer nöronlara bağlanma şekli ağıın çalışmasını önemli derecede etkilemektedir. Bugün, büyük ve profesyonel yazılımlarda kullanıcı bu bağlantılar üzerinde istediği gibi ekleme, kaldırma ve kontrol işlemi yapabilmektedir.

Bu noktaya kadar sunulan bilgiler, YSA’ların matematiksel gösterimlerinin de daha net bir şekilde anlaşılmasını sağlayabilecektir. Daha önce, McCulloch-Pitts

⁸⁴ A. H. Kramer, ve A. Sangiovanni-Vincentelli, “Efficient Parallel Learning Algorithms for Neural Networks”, *Advances in Neural Information Processing Systems*, Sayı 1, 2005, s 40-48.

tarafından tanımlanan nöron modelinin fonksiyonel gösterimi (Denklem-1) verilmişti. Belirli bir fonksiyon varsayımı içerilmeden, Şekil 3.4'teki gibi basit bir yapay nöron için Denklem-1'de verilen matematiksel notasyon şu şekilde genelleştirilebilir:⁸⁵

$$y_i = \Psi(g(x)) = \Psi\left(w + \sum_{j=0}^n w_j x_j\right) \quad ; \quad x_i = (x_0, x_1, \dots, x_n) \in \mathfrak{R} \quad (4)$$

Denklem-4 tek bir yapay nöronun matematiksel gösterimini vermektedir ama aynı zamanda tek nörondan oluşan bir sinir ağı gösterimi olarak da düşünülebilir. Oysa bir sinir ağı, tabakalar halinde sıralanmış bir çok nöron içermektedir. Dolayısıyla, tek nörona ait bu notasyonun bütün bir sinir ağının matematiksel gösterimini verecek şekilde düzenlenmesi gerekmektedir. $y = f(x_0, x_1, x_2, \dots, x_n)$ fonksiyonel ilişkisini modelleyen bir sinir ağı yapısı düşünülürse, girdi tabakasında $n+1$ adet nöron ve çıktı tabakasında bir adet nöron olacaktır. Sinir ağının gizli tabaka içermemesi durumunda ağın fonksiyonel gösterimi Denklem-4'deki tek nörona ait fonksiyonel gösterim ile aynı olacaktır. Çünkü, girdi tabakasındaki nöronlar girdi değerler üzerinde bir işlem uygulamazlar, sadece girdi değerleri bir sonraki tabakadaki nöronlara aktarırlar. Bu yüzden, sinir ağları tanımlanırken tabaka sayısı bir eksik gösterilir. Diğer bir ifadeyle, bir girdi tabakası, bir gizli tabaka ve bir çıktı tabakasına sahip bir sinir ağı üç tabakaya sahip olmasına rağmen 2-tabakalı ağ olarak tanımlanır. Girdi tabakasında işlem yapılmamasından ve çıktı tabakasında da tek nöron olmasından dolayı, sinir ağı işlem yapılan tek nörona sahiptir ve doğal olarak fonksiyonel gösterimi Denklem-4'teki gibi olacaktır.⁸⁶

Diğer taraftan, sinir ağının gizli tabaka içermesi durumunda fonksiyonel yapı değişecektir çünkü işlem yapılan nöron sayısı artacaktır. Bir gizli tabaka içerilmesi durumunda, fonksiyonel gösterim aşağıdaki gibi olacaktır:

$$y_k = f_k\left(\alpha_k + \sum_{j \rightarrow k} w_j f_j\left(\alpha_j + \sum_{i \rightarrow j} w_{ij} x_j\right)\right) \quad (5)$$

⁸⁵ W. S. McCulloch, ve W. Pitts, "A Logical Calculus of the Ideas Immanent in Nervous Activity", Bulletin of Mathematical Biophysics, Sayı 5, 1943, s115-133.

⁸⁶ McCulloch & Pitts, aynı.

Denklem-5 daha önce açıklanmamış olan bazı parametre ve fonksiyonlar içermektedir. y_k çıktı değerleri gösterirken, f_k çıktı tabakası transfer fonksiyonunu göstermektedir. α_k çıktı tabakasına ait sapma değerini, W_j çıktı tabakasına ait ağırlıkları, f_j ve α_j sırasıyla gizli tabakaya ait transfer fonksiyonunu ve sapma değerini, x_i girdi değerleri ve w_{ij} ise i girdi elemanını j gizli elemanına bağlayan ağırlığı temsil etmektedir. İki gizli tabaka olması durumunda ise bu fonksiyonel gösterim Denklem-6 şeklinde olacaktır. Gizli tabaka sayısı arttıkça bu gösterim de benzer şekilde değişmeye devam edecektir.⁸⁷

$$y_l = f_l \left(\alpha_l + \sum_{k \rightarrow l} w_l f_k \left(\alpha_k + \sum_{j \rightarrow k} w_{jk} f_j \left(\alpha_j + \sum_{i \rightarrow j} w_{ij} x_j \right) \right) \right) \quad (6)$$

Belirli bir uygulamaya yönelik bir ağ yapılandırıldıktan sonra, bu ağ artık eğitime hazır durumdadır. Bu aşama, daha önce değinilmiş olan deneyim yoluyla öğrenme özelliği için kilit önem taşımaktadır. Çünkü bu, bağlantı ağırlıklarının belirlendiği aşamadır. Genel olarak, başlangıç ağırlıkları rassal olarak seçilir ve eğitime, ya da diğer bir ifadeyle öğrenme işlemi başlar. Eğitime işlemi için “yönlendirmeli (supervised)” ve “yönlendirmesiz (unsupervised)” olmak üzere iki yaklaşım vardır. Yönlendirmeli eğitime, ağın çıktı için istenilen veri değerleri verebilmesi için girdi-çıkı ilişkisini elde edebilmesini sağlayacak bir mekanizma içermektedir. Yönlendirmesiz eğitime ise dış müdahale olmaksızın, girdilerin ağ tarafından analiz edilmesi ve bu analiz sonucunda bağlantıların oluşturulmasıdır.⁸⁸

Kullanılan ağların büyük çoğunluğu yönlendirmeli eğitimi kullanır. Yönlendirmesiz eğitime, girdiler için bazı karakter belirleme durumlarında kullanılır. Bununla beraber, kendi kendine öğrenme kavramı parlak bir gelişme potansiyeli taşısa da günümüzde tam olarak çalışmamaktadır.

Yönlendirmeli eğitimde hem girdi hem de çıktı verileri kullanılır. Öncelikle, ağ rassal olarak belirlenen başlangıç ağırlıklarını kullanarak girdileri işler ve çıktıyı istenilen çıktı ile karşılaştırır. Elde edilen hatalar sistem içinde geriye gönderilir ve bu hatalar

⁸⁷ W. S. McCulloch, ve W. Pitts, “A Logical Calculus of the Ideas Immanent in Nervous Activity”, Bulletin of Mathematical Biophysics, Sayı 5, 1943, s115-133.

⁸⁸ McCulloch & Pitts, aynı.

kullanılarak ağı kontrol eden bağlantı ağırlıkları güncellenir. Bu işlem defalarca tekrarlanır ve bağlantı ağırlıkları sürekli olarak ayarlanır (tweaked). Eğitim sırasında kullanılan veri seti “eğitime veri kümesi (training set)” olarak adlandırılır. Bir ağın eğitilmesi sırasında, aynı veri seti bağlantı ağırlıkları belirleninceye kadar defalarca işleminden geçirilir.

Bugün, yapay sinir ağı oluşturmaya yönelik programlar, bir ağın doğru cevabı öngörebilme yeteneğine nasıl yakınsadığını gözlemlemeye ve test etmeye yönelik araçlar sağlamaktadır. Diğer taraftan, sistem yalnızca (istatistiksel olarak) istenilen noktaya veya doğruluğa ulaşıncaya durdurulmaktadır ve bu durum da diğer araçlarla birleşince eğitime işlemleri günlerce sürebilmektedir. Bu arada, bazı ağlar öğrenme işlevini hiç yapamayabilir. Bunun sebebi girdi verinin istenen çıktıya ait belirli bir bilgi taşımaması olabilir. Ayrıca, tam öğrenmeyi sağlayacak kadar yeterli veri olmaması durumunda ağ yakınsamayabilir. İdeal olarak, gerekli testlerin yapılabilmesi için veri setinin bir bölümünün ayrılabilmesi kadar geniş bir veri seti gereklidir. Fazla sayıda işlem elemanı içeren çok tabakalı ağlar veri için hafıza oluşturabilme yeteneğine sahiptirler. Ağı hafızaya alma sürecinin yeterli olup olmadığının gözlenebilmesi için ise, yönlendirmeli eğitimde veri setinin bir bölümü, eğitim sonrasında gerekli testlerin yapılabilmesi için ayrılmalıdır.

Diğer taraftan, bir ağı ilgili problemi çözmemesi durumunda kullanıcının yapabilecekleri iki gruba ayrılabilir. İlk grup ağı yapısının gözden geçirilmesini kapsar. Daha açık olmak gerekirse, girdi ve çıktı verileri, tabaka sayısı, her tabakadaki eleman sayısı, tabakalar arasındaki bağlantılar, toplama, transfer ve eğitim fonksiyonları ve hatta başlangıç ağırlıkları gözden geçirilmelidir. Tüm bu kriterler, yapay sinir ağlarının sanatsal bölümü olan başarılı bir ağ oluşturmak için gereklidir. Diğer grup ise kullanıcının tercihine ve yaratıcılığına bağlı olan eğitim kurallarını içermektedir. Eğitim sırasında ağırlıkların ayarlanabilmesi için gerekli adaptif geri beslemeyi sağlayacak çok sayıda değişik eğitim kuralı (algoritma) vardır. En yaygın olan teknik geriye doğru hata beslemesi ya da bilinen ismiyle geri yayılmadır. Bu eğitim kuralları daha sonra ayrıntılı olarak açıklanacaktır.

Eğitim konusunda diğer bir önemli nokta ise öğrenmenin sürekli devam edeceğidir. Bir optimum noktaya gelindiğinde, YSA veri setinin genel istatistiksel trendine göre kendisini biçimlendirir. Bu noktadan sonra ise eğitime devam edilmesi

durumunda ağ öğrenmeye devam edecektir (bkz. Ek 1). Bu aşamada, ağ veri setinden hatalı (spurious) ilişkiler çıkartmaya başlayabilir. Bu yüzden aşırı eğitime sorununa dikkat edilmeli ve eğitime uzunluğu iyi ayarlanmalıdır.

Eğitime işlemi doğru bir şekilde tamamlandığında, yani hem daha fazla öğrenmeye gerek kalmamış hem de aşırı eğitime yapılmamışsa, istenildiği takdirde ağırlıklar dondurulabilir. Bazen, ağın ortaya çıkan son hali bir donanıma (hardware) çevrilerek daha hızlı çalışması sağlanabilmektedir. Diğer sistemler ise kullanılırken de öğrenmeye devam edebilirler.

Diğer eğitime yaklaşımı olan yönlendirmesiz yaklaşım ayrıca adaptif eğitime olarak da adlandırılır. Bu eğitime yaklaşımında, ağa girdi sağlanır ama istenilen çıktı değerler sağlanmaz. Sistem girdi veriyi gruplandırmak için hangi özellikleri kullanacağına kendi kendisine karar verir ki bu yöntem kendi kendine öğrenme (self-organization) veya adaptasyon olarak bilinir. Günümüzde, yönlendirmesiz eğitime tam olarak anlaşılammış durumdadır. Adaptif eğitmenin öncü araştırmacılarından birisi Tuevo Kohonen'dir. Kohonen, doğru cevabı bilmenin yararlarından yararlanmadan öğrenen bir ağ geliştirmiştir⁸⁹. Bu ağ, bir çok sayıda bağlantısı olan tek tabakaya sahip olması nedeniyle biraz sıra dışı sayılabilir.

Ayrıca, diğer belirgin özellik olarak, bu ağın bağlantı ağırlıkları için başlangıç değerleri verilmelidir ve girdi değerler normalize edilmelidir.⁹⁰

Kohonen, daha sonra çalışmalarını bu standart yapının dışındaki ağlara, ileri besleme ve geri yayılma yaklaşımlarına yöneltmiştir. Kohonen'in çalışması nöronları belirli alanlara gruplandırmakla ilgilidir. Bir alanın içerdiği nöronlar topolojik olarak sıralanmıştır (topologically ordered). Topoloji, matematiğin bir dalıdır ve geometrik yapıyı değiştirmeden bir boyuttan diğerine haritalamanın (mapping) nasıl yapılacağı ile ilgilenir. Kohonen, sinir ağı modellerinde topolojik sıralamanın olmamasının bugünkü sinir ağlarını, beyin içindeki gerçek sinir ağlarının basit bir çıkarımsaması (abstraction) haline getirdiğini belirtmiştir. Bu araştırmalar devam ettikçe daha etkili kendi kendine

⁸⁹ Kendi kendine öğrenen (self-organizing) yapılar ilk olarak Malsburg (1973) ve Willshaw ve Malsburg (1976) tarafından ortaya atılmıştır. Fakat bu konudaki temel gelişme Kohonen (1982) tarafından sağlanmıştır.

⁹⁰ T. Kohonen, "Self-organised Formation of Topologically Correct Feature Maps", Biological Cybernetics, Sayı 43, 1983, s 59-69.

öğrenen ağlar elde edilebilir. Fakat, şu an için bu alan sadece deney ortamlarında kalmaktadır.

Öğrenme (veya adaptasyon) YSA'ların yapısı içinde önemli bir yere sahiptir. Çünkü YSA'ların bazı önemli özellik ve avantajlarının kaynağını oluşturmaktadır. Bu yüzden, YSA yapısı içindeki öğrenme sürecine yönelik elemanlar büyük önem taşımaktadır. Bu elemanların ilki öğrenme fonksiyonudur. Öğrenme fonksiyonunun amacı her işlem elemanının girdilerine ait değişken bağlantı ağırlıklarını ayarlamaktır. Girdi bağlantı ağırlıklarının, istenilen sonucu elde edecek şekilde değiştirilmelerini sağlayan bu işlem adaptasyon fonksiyonu olarak da adlandırılmaktadır.

İkinci eleman ise hata fonksiyonudur. Öğrenme fonksiyonunun gerekli ayarlamaları yapabilmesi için yanılma payının biliniyor olması gerekmektedir. Hata fonksiyonu, bu amaca yönelik olarak, o anki çıktı ile istenilen çıktı arasındaki farkı, hatayı, hesaplar ve gerekiyorsa bir transformasyon uygular. Bu hata, literatürde cari hata (current error) olarak adlandırılır ve bu hata veya transformasyonu sağlanmış hali (geri yayılma değeri) genellikle önceki tabakaya geri yayılır. Bu geri yayılma değeri, bir sonraki öğrenme döngüsünde öğrenme fonksiyonu tarafından bağlantıları ayarlamak için, tabii ki gerekli ise, kullanılır.

Diğer bir eleman ise öğrenme oranıdır. Öğrenme oranı, öğrenme sürecinin hızı ve işlevi açısından önemlidir. Çünkü, YSA'ların öğrenme gücü ile hızı ters orantılıdır. Basit bir şekilde, bir adımda daha fazla öğrenme, daha düşük bir hız ve dolayısıyla daha fazla zaman anlamına gelmektedir. Diğer bir ifadeyle, daha fazla hız daha az öğrenme anlamına gelmektedir. Sonuç olarak, bir ağın ne kadar eğitileceği sorusu öğrenme oranına bağlıdır. Öğrenme oranının belirlenmesinde ise ağın karmaşıklık düzeyi, büyüklüğü, mimarisi, kullandığı öğrenme kuralı ve istenilen doğruluk derecesi gibi bir çok faktör rol oynar. Çoğu öğrenme fonksiyonu, öğrenme oranı için belirli standartlara sahiptir. Öğrenme oranı genellikle (0,1) gibi bir aralık içinde belirlenir. Bu aralıkta, öğrenme oranının küçük değeri alması, yavaş bir öğrenme süreci getirecektir. Diğer taraftan ise, öğrenme sürecinin küçük adımlar halinde olması maksimum doğruluk derecesine yakınsamayı getirebilecektir.

Ek 2'de Yapay Sinir Ağlarının çalışma şeklini basit bir şekilde anlatan bir örnek model çözümü sunulmuştur. YSA metodolojisi ve teorisi hakkında buraya kadar anlatılanların daha net anlaşılmasını ve daha sonra anlatılan uygulamalar ile kolaylıkla

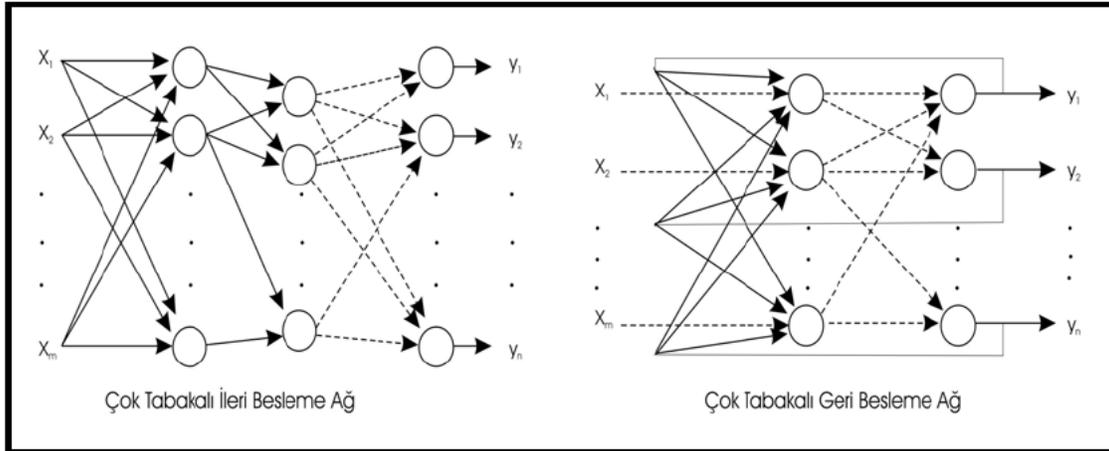
birleştirilebilmesini sağlayabileceği düşünölen bu örnekle çözüm Balkin (2001)'den alınmıştır.

3.3. YSA Çeşitleri

YSA'ların çok sayıda farklı çeşitleri vardır. Bu farklılıkların kaynağı mimarisi, öğrenme yöntemi, bağlantı yapısı vb. olabilmektedir. Genel olarak, YSA'lar üç ana kritere göre sınıflandırılmaktadırlar. Bu kriterlerden biri öğrenme yöntemidir. Önceki bölümde belirtildiği gibi, temel olarak iki çeşit öğrenme algoritması vardır: yönlendirmeli öğrenme ve yönlendirmesiz öğrenme. Her yöntemin kullandığı öğrenme kuralı değişebilmekteyse de, YSA'lar bu iki algoritmaya göre sınıflandırılırlar.

İkinci bir sınıflandırma, ağıın kullandığı veriye göre yapılmaktadır. Temel olarak, kalitatif ve kantitatif olmak üzere iki tür veri vardır. Kalitatif verilerle çalışan ağılar, ister yönlendirmeli ister yönlendirmesiz öğrenme kullansın, sınıflandırma ağıları olarak bilinirler. Kantitatif veriler kullanan yönlendirmeli eğitim ise regresyon olarak adlandırılmaktadır.

Son sınıflandırma kriteri ise ağıın yapısıdır. Bazı ağılar ileri besleme şeklinde yapılandırılırken, bazı ağılar ise geri besleme yapısı içermektedir. İleri besleme sinir ağılarında, işlem elemanları arasındaki bağlantılar bir döngü oluşturmazlar ve bu ağılar girdi veriye genellikle hızlı bir şekilde karşılık üretirler. Geri beslemeli ağılarda (Recurrent Networks) ise bağlantılar döngü içerirler ve hatta her seferinde yeni veri kullanabilmektedirler. Bu ağılar, döngü sebebiyle girdinin karşılığını yavaş bir şekilde oluştururlar. Bu yüzden, bu tür ağıların eğitim süreci daha uzun olmaktadır. Ayrıca, hem ileri besleme hem de geri yayılma olarak tanımlanabilecek ağı yapıları da mevcuttur. Şekil 3.10'da, bir kıyaslamaya imkan tanıyabilmek için, çok tabakalı ileri besleme ağı yapısı ile birlikte çok tabakalı geri besleme ağı yapısı örneklendirilmiştir.



Şekil 3.10: İleri Beslemeli ve Geri Beslemeli Ağ Yapıları

(Hasan Yurtoğlu, “Yapay Sinir Ağları ile Öngörü Modellenmesi.” Uzmanlık Tezi, DPT 2005.

S.28)

Bu çok geniş YSA çeşitleri yelpazesinde en çok bilinen ve kullanılan ağlar arasında hata algoritması genellikle geri yayılma ile eğitilen çok tabakalı perceptron⁹¹ (Geri-Yayılma Ağ – Backpropagation Network), radyal tabanlı fonksiyon (radial basis function), Hopfield ve Kohonen sayılabilir. Çok fazla çeşit ve yoğun bir literatür olması nedeniyle, burada tüm ağ çeşitleri hakkında bilgi verilmemektedir.⁹² Bunun yerine, sadece bu çalışmada kullanılan ağ çeşidi detaylı bir şekilde incelenmektedir.

Bu çalışmada, bir Geri Yayılma Yapay Sinir Ağı (GYSA) kullanılmaktadır. Geri yayılma ağlar, çok tabakalı perceptron ile aynı yapıya sahiptirler ve öğrenme yöntemi olarak geri yayılma algoritması kullanırlar. Dolayısıyla, bu ağlar ileri besleme ağlar sınıfına girmektedirler. Ayrıca, çalışmada kullanılan ağ kantitatif verilerle çalışmaktadır ve yönlendirmeli öğrenme yöntemi kullanmaktadır. Bu YSA türünün seçilmesinin temel sebebi öngörü (prediction) ve sınıflandırma işlemleri için oldukça uygun olmasıdır. Diğer bir önemli neden ise doğrusal olmayan yapılar için de oldukça kullanışlı olmasıdır.

İleri beslemeli Geri Yayılma mimarisi 1970’li yıllarda geliştirilmiştir. Bu mimarinin geliştirilmesinde birbirlerinden bağımsız olarak birkaç araştırmacının katkıları olmuştur.⁹³ Asıl katkı ise Rumelhart, Hinton ve Williams (1986) tarafından yapılmıştır. Ortaya çıkışından sonra, hem etkili hem de çok kullanışlı olmasından dolayı büyük bir

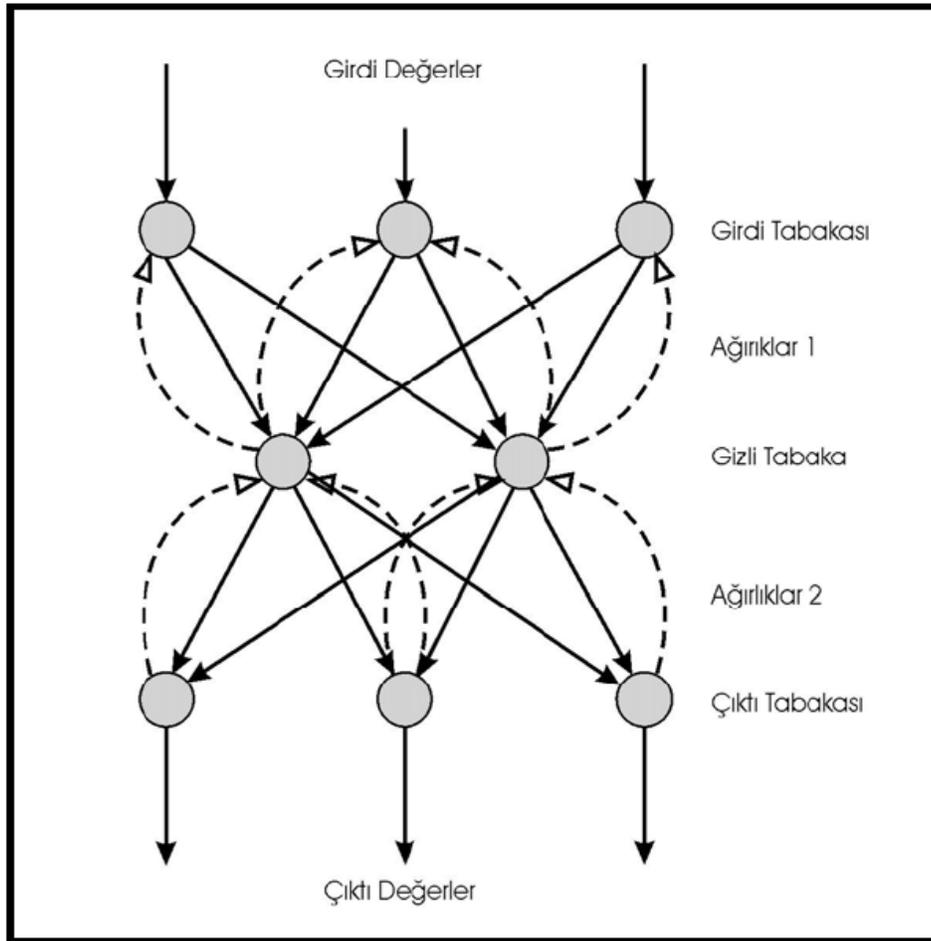
⁹¹ İleri besleme ağ yapıları YSA literatüründe genellikle Perceptron olarak adlandırılmaktadır.

⁹² Hem burada listelenen hem de diğer YSA çeşitleri ve ayrıntıları için bkz. Haykin (1999) ve Zurada (1992).

⁹³ Werbor (1990), Parker (1987), Rumelhart, Hinton ve Williams (1986).

popülerite kazanmıştır ve hala en çok kullanılan ağ türü olarak bilinmektedir. Çok sayıda farklı uygulama alanında kullanılmaktadır ve en büyük özelliği doğrusal olmayan yapı içeren problemlerde de etkili olabilmesidir.

Tipik bir geri yayılma ağ mimarisinde bir girdi tabakası, bir çıktı tabakası ve bu iki tabaka arasında en az bir adet gizli tabaka bulunur. Gizli tabaka sayısı için herhangi bir kısıt yoktur fakat, genellikle bir ya da iki gizli tabaka kullanılmaktadır. Bu ağ çeşidinin genel yapısı Şekil 3.11’de örneklenmektedir.



Şekil 3.11: İleri Beslemeli Geri Yayılma Ağların Genel Yapısı

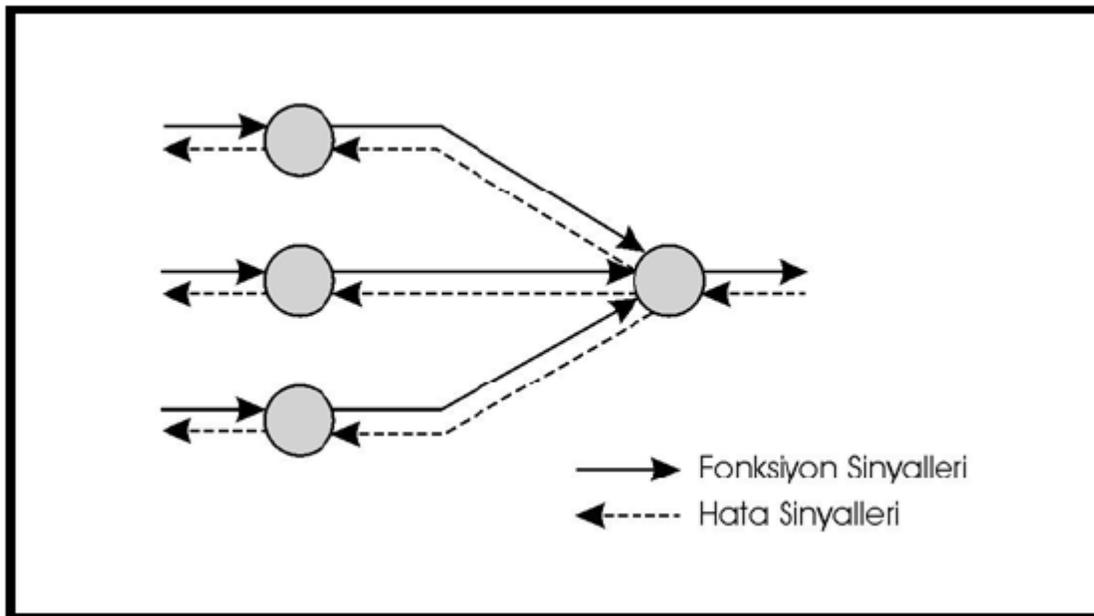
(Hasan Yurtoğlu, “Yapay Sinir Ağları ile Öngörü Modellenmesi.” Uzmanlık Tezi, DPT 2005.

S.30)

Şekilde, bir girdi tabakası, bir gizli tabaka ve bir çıktı tabakası içeren bir geri yayılma ağ yapısı örneklenmektedir. Tabakalar halinde düzenlenmiş daireler işlem elemanlarını yani nöronları temsil etmektedir. Girdi tabakasında üç nöron bulunmaktadır, yani ağa girdi olarak üç değişken tanıtılmaktadır. Bunun dışında gizli tabakada iki nöron,

çıkı tabakasında ise üç nöron bulunmaktadır. Dolayısıyla, ağdan üç değişken olarak çıkı alınmaktadır. Girdi tabakasından, gizli tabakaya iletilen değerler “Ağırlıklar 1” ağırlık seti ile gizli tabakadan çıkı tabakasına iletilen değerler ise “Ağırlıklar 2” ağırlık seti ile ağırlıklandırılmaktadır. Ağ yapısında, kalın oklar *anımsama* sırasındaki bilgi akışını simgelemektedir. Anımsama, eğitilmiş bir ağa yeni girdi verilerin sunulması ve çıkısının alınması işlemidir. Bu yüzden, anımsama işlemi sırasında geri yayılma işlemi kullanılmaz. Geri yayılma sadece eğitme sürecinde kullanılır, dolayısıyla eğitme sürecindeki bilgi akışı şekildeki tüm oklar ile gösterilmektedir.

Sonuç olarak, bu ağ yapısının eğitme sürecinde iki çeşit sinyal tanımlanmaktadır. Birbirine zıt yönde çalışan bu iki sinyal çeşidi *fonksiyon sinyalleri* ve *hata sinyalleri* olarak adlandırılmaktadırlar⁹⁴. Şekil 3.12’de küçük bir ağ bölümü kullanılarak bu sinyallerin yönleri gösterilmektedir. Şekilde, sol taraf girdi veri tarafını, sağ taraf çıkı tarafını ve yuvarlaklar ise nöronları göstermektedir.



Şekil 3.12: Eğitme Sürecindeki Sinyal Çeşitleri

Fonksiyon sinyali, ağa girdi tabakasından giren, ağ içinde ileri doğru yayılan ve çıkı tabakasından çıkı sinyali olarak çıkan bir girdi sinyalidir. Bu tür bir sinyalin

⁹⁴ D. B. Parker, “Optimal Algorithms For Adaptive Networks: Second Order Back Propagation, Second Order Direct Propagation, and Second Order Hebbian Learning”, IEEE 1st International Conference on Neural Networks, Sayı 2, 1987, s.553-600, San Diego, CA.

fonksiyon sinyali olarak adlandırılmasının iki temel sebebi vardır. İlk olarak, ağın çıktısı için gerekli fonksiyonları uyguladığı kabul edilmektedir. İkinci sebep ise fonksiyon sinyalinin geçtiği her nöronda, sinyal girdilerin ve o nörona uygulanan ağırlıkların bir fonksiyonu olarak hesaplanır. Fonksiyon sinyalleri, girdi sinyalleri olarak da adlandırılmaktadırlar. Hata sinyali ise, fonksiyon sinyalinin tersine, çıktı tabakasından başlar ve tabaka tabaka geriye doğru yayılır. Hata sinyali olarak adlandırılmasının sebebi, tüm nöronlarda bir hata tabanlı fonksiyon ile hesaplanmasıdır.

Ağın genel yapısına dönersek, tabaka sayısı ve tabakaların içerdiği işlem elemanı sayısı ağın performansı açısından önemli ve zor kararlardır. Zor karar olmalarının sebebi ise herhangi bir uygulama için net bir seçim kriterinin olmamasıdır. Bunun yerine, uygulamalar sonucunda ortaya çıkmış ve araştırmacılar tarafından benimsenmiş bazı kurallar vardır. Bu kurallar şu şekilde özetlenebilir:

Kural-1: Girdi ve çıktı veriler arasındaki ilişkinin karmaşıklık derecesi arttıkça, tabakaların içerdiği işlem elemanı sayısı da artmalıdır.

Kural-2: Modellenen konu değişik safhalara ayrılabilirse, tabaka sayısının artırılması gerekebilir.

Kural-3: Eldeki eğitme verisinin genişliği, gizli tabakalardaki toplam nöron sayısı için bir üst limit kriteri oluşturur.⁹⁵

Geri yayılma ağlarda çok çeşitli öğrenme kuralı, hata fonksiyonları ve transfer fonksiyonları kullanılabilir. Öğrenme kuralı olarak genellikle *Delta Kuralı*'nin bir varyantı kullanılmaktadır. Delta kuralı, ağın çıktısı ile istenilen çıktı arasındaki farkın hesaplanması ile başlar. Bu hata kullanılarak bağlantı ağırlıkları belirli bir doğruluk derecesi faktörüne göre güncellenir. Bu öğrenme mekanizmasının komplike olan tarafı, hatalı çıktı üretilmesinde hangi işlem elemanının daha etkili olduğunun belirlenmesi ve hatanın düzeltilmesi için bu işlem elemanının nasıl değiştirileceğidir. Bu noktada aktif olmayan bir nod hataya sebep olamaz ve dolayısıyla ağırlıklarını değiştirmeye gerek yoktur. Bu sorunun çözümü için, eğitme setine ait girdi veriler ağın girdi tabakasına sunulur ve istenilen çıktılarla karşılaştırma çıktı tabakasında gerçekleştirilir. Öğrenme işlemi süresince, ağ içinde ileri doğru bir bilgi akışı vardır ve tabaka tabaka her işlem elemanının çıktısı hesaplanır. Çıktı tabakasına ulaşıldığında, bu tabakanın çıktısı ile

⁹⁵ Üst limit kriteri hakkında bilgi Ek 3'te sunulmuştur.

istenilen çıktı arasındaki fark hesaplanır ve bu hata önceki tabakalara iletilir (geri yayılma). Bu süreçteki önemli nokta ise, hata önceki tabakalara iletilirken, transfer fonksiyonunun türevi ile bir transformasyon işlemi uygulanmasıdır. Hatanın iletilmesi, tabaka tabaka geriye doğru olur ve bu süreçte Delta Kuralı ile bağlantı ağırlıkları ayarlanır. İşlem, girdi tabakasına ulaşılan kadar devam eder ve bu noktada yeni bir döngüye başlar.

Geri yayılma algoritmasında, Delta Kuralı ile bağlantıların ayarlanmasının matematiksel gösterimi şu şekilde özetlenebilir. Delta Kuralı, temel olarak, ilgili bağlantı ağırlığının ayarlanması için gerekli olan düzeltme miktarını formüller. Buna göre, nöron(i) ve nöron(j) arasındaki bağlantı için düzeltme miktarı şu şekilde hesaplanır:⁹⁶

$$\begin{array}{l} \text{Ağırlık} \\ \text{Düzeltilme} \\ \text{Miktarı} \end{array} = \begin{array}{l} \text{Öğrenme} \\ \text{Oranı} \\ \text{Parametresi} \end{array} * \begin{array}{l} \text{Yerel} \\ \text{Değişim} \\ \text{(Gradient)} \end{array} * \begin{array}{l} \text{Nöron(j)} \\ \text{İçin Girdi} \\ \text{Sinyali} \end{array}$$

veya matematiksel formül olarak:⁹⁷

$$\Delta w_{ji}(n) = \eta * \delta_j(n) * Y_i(n)$$

Burada dikkat edilmesi gereken nokta, yerel değişimin hesaplanma şeklinin nöron(j)'nin çıktı veya gizli nöron olmasına göre değişiklik gösterdiğidir. Buna göre:

- Nöron(j) bir çıktı nöronu ise, yerel değişim, nöron(j)'ye ait hata sinyali ve fonksiyon sinyalinin türevinden hesaplanmaktadır.
- Nöron(j) bir gizli nöron ise, yerel değişim, fonksiyon sinyalinin türevi ve bir sonraki tabakadaki nöronlara ait değişimlerin ağırlıklı toplamı kullanılarak hesaplanır.

Burada, Delta Kuralının içerdiği düzeltme formülünün mantığı ve bileşenleri hakkında bilgi bir özet halinde sunulmuştur. Daha ayrıntılı bilgi içinse Haykin (1999) ve Zurada (1992)'ye bakılabilir. Ayrıca, diğer öğrenme kuralları için bazı temel bilgilere Ek 4'te yer verilmiştir.

Son olarak, geri yayılma ağların bazı kısıtlamalara da sahip olduğu belirtilmelidir. Geri yayılma mekanizması oldukça geniş bir girdi-çıkı veri seti ile geniş çaplı bir

⁹⁶ D. C.Montgomery, L. A. Johnson, ve J. S. Gardiner, Forecasting & Time Series Analysis, McGraw Hill, Inc. 1990, s.417-420

⁹⁷ Montgomery, Johnson ve Gardiner, aynı.

yönlendirmeli eğitmeye ihtiyaç duyar. Ek olarak, içsel haritalama yapısı tam olarak anlaşılmadığından sistemin istenilen doğruluk derecesine yakınsayamaması ihtimali de mevcuttur.

3.4. *Niçin YSA?*

Teknolojik gelişme olarak da görülmesi gereken yapay sinir ağları metodolojisi, özellikleri ve yapabildikleri sayesinde önemli avantajlar sunmaktadır. Bu bölümde, YSA'ların farklılık ve avantaj sağladığı noktalar incelenmektedir.

Doğrusal Olmayan Yapı

YSA'ların en önemli özelliklerinden birisi gerçek hayattaki olası doğrusal olmayan yapıları da dikkate alabilmesidir. White (1991) YSA'ların doğrusal olmayan modeller olarak görülebileceğine dair bulgular ortaya koymuştur. "... Doğrusal olmayan modellerde kullanılan belirli fonksiyonel yapılar, veriyi üreten fonksiyonun genellikle YSA'ların ima ettiğiinden farklı olduğu ve bu yüzden YSA'ların kullanılması için gerekli ekonometrik teorinin eksik tanımlı doğrusal olmayan modeller için olduğunu ima etmektedir. Bunların ön tanımlı yapıları dayanıksızken, YSA'lar herhangi bir sürekli fonksiyona veya türevlerine yakınsama yeteneğine sahiptir ve bu yüzden Evrensel Fonksiyon Yakınsayıcı Yöntem (Universal Function Approximators) olarak tanımlanmaktadırlar."⁹⁸ Doğrusal olmayan yapıları dikkate alabilme özelliği bu çalışmanın içeriği açısından da ayrıca önem taşımaktadır. Çünkü yapıları gereği ekonomik verilerin de doğrusal olmayan bir yapıda olmaları normaldir fakat tahmin zorlukları nedeniyle analizler genellikle lineer yöntemlerle gerçekleştirilmektedir. Hâlbuki bu durum, muhtemel bir doğrusal olmayan yapı içerilmesi durumunda yanlış sonuçlara yol açabilmektedir; ya da en azından analizi yapılan sistemde açıklanamayan bileşenler kalabilmektedir. Sonuç olarak, analiz konusunun içerdiği veri setinin doğrusal veya doğrusal olmayan yapı içeriyor olması, analiz sonuçlarını etkileyecek önemli bir faktördür. Bu yüzden, doğrusal olmayan yapıları dikkate alabilmesi YSA'ların önemli bir özelliğidir. Bunun ötesinde, bu çalışma kapsamında, YSA'ların bu özelliği sayesinde Türkiye ekonomisine ait verilerin doğrusallık özellikleri hakkında bazı sonuçlar elde edilebilecektir ki bu tür bir bulgu önemli bir katkı olarak görülmelidir.

⁹⁸ A. Beltratti, & S. Margarita, ve P. Terna. Neural Networks for Economic and Financial Modelling, International Thomson Computer Pres, 1996. S.127

Öğrenme

YSA'ların diğer bir önemli avantajı en önemli özelliğinden kaynaklanmaktadır. Esin kaynağı insan beyninin çalışma sistemi olan bu yöntem, eğitime veya başlangıç tecrübesi sayesinde veriyi kullanarak öğrenme yeteneğine sahiptir. Bu özelliği sayesinde ise geleneksel teknikler için çok karmaşık kalan problemlere çözüm sağlayabilmektedirler. Ayrıca, insanların kolayca yapabildiği ama geleneksel metotların uygulanamadığı basit işlemler için de oldukça uygundur.

Yerel İşlem ve Esneklik

YSA'lar, geleneksel işlemcilerden farklı şekilde işlem yapmaktadırlar. Geleneksel işlemcilerde, tek bir merkezi işlem elemanı her hareketi sırasıyla gerçekleştirir. YSA modelleri, her biri büyük bir problemin bir parçası ile ilgilenen çok sayıda basit işlem elemanlarından oluşma ve bağlantı ağırlıklarının ayarlanabilmesi gibi özelliklerinden dolayı önemli derecede esnek bir yapıya sahiptirler. Bu esnek yapı sayesinde ağırlık kısmının zarar görmesi modelde sadece performans düşüklüğü yaratır. Modelin işlevini tamamen yitirmesi söz konusu olmaz. Ayrıca, toplam işlem yükünü paylaşan işlem elemanlarının birbirleri arasındaki yoğun bağlantı yapısı sinirsel hesaplamanın temel güç kaynağıdır. Bu yerel işlem yapısı sayesinde, YSA yöntemi en karmaşık problemlere bile uygulanabilmekte ve tatminkar çözümler sağlayabilmektedir.

Gerçek Zamanlı İşlem

YSA hesaplamaları paralel olarak yürütülebildiğinden gerçek zamanlı işlem yapabilir.

Genelleme

Yine öğrenme yeteneği sayesinde bilinen örnekleri kullanarak daha önce karşılaşılmamış durumlarda genelleme yapabilmektedir. Yani, hatalı (noisy) veya kayıp veriler için çözüm üretebilmektedir. YSA'lar, tanımlanmamış girdi veriler hakkında karar verirken genelleme yapabildikleri için iyi birer gidişat tanımlayıcısı (pattern recognition engine) ve sağlam sınıflandırıcıdır (robust classifier).⁹⁹

Hafıza

Bunlara ek olarak, işlem elemanları arasındaki ağırlıklı bağlantılar sayesinde dağıtılmış hafızada bilgi saklayabildikleri söylenebilir.

⁹⁹ Şakir Kocabaş. Yapay Zeka Ders Notları, İstanbul Teknik Üniversitesi. 1998-1999

Kendi İlişkisini Oluşturma

Yapay sinir ağları, bilgilere (verilere) göre kendi ilişkilerini oluştururlar, denklem içermezler.¹⁰⁰

Sınırsız Sayıda Değişken ve Parametre

Diğer taraftan, YSA modelleri sınırsız sayıda değişken ve parametre ile çalışabilmektedir. Bu sayede mükemmel bir öngörü doğruluğu ile genel çözümler sağlanabilmektedir.

Karmaşık veya sorunlu veriden bile anlam çıkarabilmek gibi dikkate değer yetenekleriyle YSA'lar, insanlar veya bilgisayarlar tarafından anlaşılması zor trendleri belirlemek veya yapıları (pattern) çıkartmak için kullanılabilirler. Tam eğitilmiş bir Yapay Sinir Ağı modeli, analiz ettiği bilgi kümesi (veri tabanı) için uzman olarak düşünülebilir. Bu uzman, değişik durumlar ve '... olsa ne olur?' türünde simülasyon problemlerine projeksiyonlar sağlamak için kullanılabilir. Bununla birlikte, YSA'ların kullanımında göz önünde bulundurulması gereken bazı dezavantajlar da bulunmaktadır. Bunlar arasında en önemlisi geniş veri seti gereksinimidir. Sinir ağlarının eğitilebilmesine ve test edilebilmesine yetecek genişlikte veri setine ihtiyaç duyulmaktadır. Yine de, yeterli veri seti genişliği için kesin bir kriter yoktur; bir noktada uygulamaya bağlıdır. Dezavantaj sayılabilecek diğer bir nokta ise basit olarak görülebilecek modelleme yapılarına rağmen uygulamanın zor ve karmaşık olabilmesidir. Bazı durumlarda, bir yakınsama sağlamak bile imkansız olabilmektedir fakat bu durum da uygulama alanına bağlıdır ve genellikle çok karmaşık problemlerde ortaya çıkmaktadır.

3.5. Tarihsel Gelişim

1950'li yılların sonlarında, büyük ölçekli işlemcilerin geliştirilmesiyle, beynin yaptığı işlemleri yapabilecek sinir ağlarının oluşturulabilmesi mümkün hale gelmiştir. Gerçekten de, YSA'lar dijital işlemcilerin geliştirilmesinden sonra işlem yöntemi olarak önemli bir yeni yaklaşım olarak görülmektedir.

YSA simülasyonları nispi olarak yeni bir gelişme olarak görülmektedir. Bununla beraber, bu alan bilgisayarın çıkışından önce ortaya çıkmıştır ve bir bocalama devresi geçirdikten sonra yoluna devam etmiştir.

¹⁰⁰ Şakir Kocabaş. Yapay Zeka Ders Notları, İstanbul Teknik Üniversitesi. 1998-1999

Bilgisayarların yaygın bir şekilde kullanılmaya başlanmasıyla birlikte, YSA alanında oldukça önemli gelişmeler olmuştur. Bu alandaki araştırmalar ve çalışmalar büyük bir ilgi ile başlamış fakat beklenen gelişmelerin gerçekleşmemesi sonucunda ilgi azalmış ve bir suskunluk dönemi başlamıştır. Profesyonel ve maddi katkının minimum olduğu bu dönemde, sadece birkaç araştırmacı tarafından katkı sağlanmıştır. Bu araştırmacılar, Minsky ve Papert tarafından tanımlanan sınırlamaları etkisiz kılan bir teknoloji geliştirmişlerdir. Minsky ve Papert, 1969 yılında bir kitap yayınlamışlardır ve bu kitapta, araştırmacılar arasında ön plana çıkan ve ekstra analiz yapılmadan kabul gören YSA'lara karşı bazı olumsuzlukları toplamışlardır. Son yıllarda ise, YSA alanı ilgi ve katkı olarak yeniden canlanmaktadır. YSA tarihi, dönemler itibariyle incelenebilir.

1. İlk Girişimler: Bu dönemde, genel mantığı kullanan başlangıç simülasyonları yapılmıştır. McCulloch ve Pitts (1943), kendi nöroloji anlayışları çerçevesinde YSA modelleri geliştirmişlerdir. Bu modeller, nöronların çalışma şekilleri hakkında bazı varsayımlarda bulunmuştur. Oluşturdukları ağlar, sabit eşiklere sahip ikili (binary) aletler olarak görülen basit nöronları baz almıştır. Modellerinin sonuçları, “a veya b” ve “a ve b” gibi basit mantıksal fonksiyonlardı. Diğer bir girişim, bilgisayar simülasyonları kullanılarak yapılmıştır. Bu noktadaki katkılar iki araştırmacı grubu tarafından yapılmıştır: Farley ve Clark (1954)¹⁰¹ ve Rochester, Holland, Haibit ve Duda (1956)¹⁰². Özellikle ilk grup, ki bunlar IBM araştırmacılarıdır, modellerini çalıştıramamışlar ve McGill Üniversitesinden nörobilimcilerle ortak bir çalışma yapmışlardır. Bu etkileşim, günümüze kadar süren, çok disiplinli bir trend oluşturmuştur.

2. Umut Verici Gelişmeler: YSA'ların gelişmesinde tek etkisi olan nöroloji değil, psikologlar ve mühendisler de YSA simülasyonundaki ilerlemeye katkı sağlamıştır. Rosenblatt (1958)¹⁰³ Perceptron'u tasarlayıp geliştirdikten sonra, bu alandaki ilgi ve etkinlik canlanmaya başlamıştır. Perceptron üç tabaka içermekteydi ve orta tabaka birleştirme tabakası olarak adlandırılmaktaydı. Bu sistem, bir veri girdi kümesinin bir rassal çıktıya bağlanma veya birleşme şeklini öğrenebilmekteydi. Burada öğrenme kelimesi bağlantı ağırlıklarının ilişkiye göre ayarlanması anlamında kullanılmaktadır.

¹⁰¹ Bakınız: Anderson ve McNeil (1992)

¹⁰² Bakınız: Anderson ve McNeil (1992) ve Haykin (1999)

¹⁰³ Bakınız: Anderson ve McNeil (1992) ve Haykin (1999)

Diğer bir sistem (ADALINE – Adaptive Linear Element) ise Stanford Üniversitesinden Widrow ve Hoff tarafından 1960 yılında geliştirilmiştir. Basit bileşenlerden oluşan bir analog elektronik alet olan ADALINE, kullanılan öğrenme yöntemi ile Perceptrondan farklılaşmıştır. Bu sistemde En Küçük Ortalama Kareler (LMS – Least Mean Squares) öğrenme kuralı kullanılmıştır.

3. Olumsuz Gelişmeler: 1969 yılında, Minsky ve Papert bir kitap yazmış ve bu kitapta çok tabakalı sistemlere göre tek tabakalı Perceptronların sahip olduğu sınırlamaları ortaya koymuşlardır. Kitabın ana fikri şu şekilde özetlenebilir: “...bizim sezgisel görüşümüz çok tabakalı sistemlere genişlemenin verimsiz olduğudur.”. Kitapta ortaya konulan bu önemli sonuç sonrasında YSA simülasyonlarına yönelik araştırmalar hem ilgi hem de kaynak kaybına uğramıştır. Sonuç olarak, bu alana yönelik önemli bir önyargı oluşmuştur. Minsky ve Papert tarafından altı çizilen sorun YSA literatüründe XOR Problemi olarak bilinmektedir. Ek 5’te bu probleme yönelik genel bilgiler sunulmuştur.

4. Yenilikler: İlgi ve kaynağın minimum düzeyde olmasına rağmen bazı araştırmacılar yapı tanımlama (pattern recognition) gibi problemlerin çözümüne yönelik çalışmalarını sürdürmüşlerdir. Bu dönem süresince bazı paradigmlar ortaya çıkmıştır. Grossberg ve Carpenter (1995)¹⁰⁴ tarafından yapılan çalışmalar, yankı (resonating) algoritmaları araştıran bir düşünce okulunun temellerini atmıştır. Bu araştırmacılar, temeli biyolojik olarak teorik gelişmelerle ilgilenmiştir. Adaptif yapı (pattern) sınıflandırması konusu üzerine bir makale yayınlamıştır ve bu makalede bir öğrenme temeli (error-correction method – hata düzeltme metodu) için bir matematiksel teori oluşturmuştur. Fukushima ise el yazısı karakterleri yorumlamak için bir adım adım (step wise) eğitilmiş çok tabakalı YSA oluşturmuştur. Cognitron olarak adlandırılan bu model 1975 yılında yayınlanmıştır. makul modellere dayanan ART (Adaptive Resonance Theory – Adaptif Rezonans Teorisi) ağlarını geliştirmişlerdir. Anderson ve Kohonen ise birbirlerinden bağımsız olarak benzer teknikler geliştirmişlerdir. Klopff, 1972 yılında, yapay nöronlarda öğrenme işlemi için, “heterostasis” olarak adlandırılan ve nöronsal öğrenmenin biyolojik prensiplerine dayanan bir temel oluşturmuştur. Werbos (1974)¹⁰⁵ geri-besleme öğrenme metodunu geliştirmiş ve kullanmıştır ve bir kaç yıl sonrasında bu metot oldukça

¹⁰⁴ Bakınız: Haykin (1999)

¹⁰⁵ Bakınız: Anderson ve McNeil (1992) ve Haykin (1999)

popülerite kazanmıştır. Geri-besleme ağlar, bugün, en çok bilinen ve kullanılan yapay sinir ağlarıdır. Geri-besleme ağ aslında, yapay nöronunda farklı bir eşik fonksiyonuna sahip ve daha sağlam (robust) ve yetenekli öğrenme kuralı olan bir çok tabakalı Perceptrondur. Amari (1967)¹⁰⁶

5. Yeniden Canlanma: 1970’li yılların sonlarında ve 1980’li yılların başlarındaki ilerleme, yapay sinir ağları alanına ilginin yeniden canlanması bakımından önemlidir. Bu hareketi bir kaç faktör etkilemiştir. Örneğin, ayrıntılı kitaplar ve konferanslar çok farklı alanlarda uzmanlaşmış insanlara bir forum imkânı ve dolayısı ile bir etkileşim sağlamıştır. Akademik programlar oluşturulmuş ve en önemli üniversitelerde dersler açılmıştır. Artan ilgi ile beraber bu alandaki araştırmalara yönelik fonlar da artmış ve enstitüler ortaya çıkmıştır.

6. Bugün: Sağlanan önemli ilerleme yapay sinir ağları alanında daha ileri araştırmalar için gerekli ilgi ve bilgi birikimini sağlamıştır. Sinir sistemi tabanlı işlemciler oluşturulmakta ve komplike problemlerin çözümüne yönelik uygulamalar gelişmektedir. Kısacası, bu alan günümüzde bir geçiş dönemi içinde görülmektedir. YSA’lar 1950’li yıllarda ortaya çıkmalarına rağmen, ancak 1980’li yılların ortalarında genel amaçlı kullanım için yeterli seviyeye gelmişlerdir.

3.6. YSA, İstatistik ve Ekonomi

İstatistik ile ekonomi arasındaki ilişki sürekli gelişmektedir. Özellikle, ekonomi alanında istatistiksel yöntemlerin kullanımı giderek artmaktadır. Ekonomi bilimindeki teorik ilişkilerin ölçülmesi ve kanıtlanmasından politika oluşturmaya yönelik tahmin ve öngörülerin yapılmasına kadar pek çok konuda istatistiksel araçlar sıkça kullanılmaktadır. Özellikle, son dönemde zaman serileri alanında kaydedilen gelişmeler sayesinde bu ilişki ivme kazanmıştır.

Özellikle, bu çalışmanın da konusunu oluşturan, ekonomik değişkenlerin modellenmesi ve tahmin edilmesi konusu ekonomi alanı için oldukça önem taşımaktadır ve genellikle istatistiksel yöntemlerin kullanımını gerektirmektedir. Bu ilişkinin öneminin giderek artması istatistik alanındaki, özellikle de zaman serileri alanındaki gelişmelerin itici güçlerinden birini oluşturmaktadır. Durağanlık, ko-entegrasyon ve vektör otoregresyon (Vector Autoregression - VAR) gibi son dönemde zaman serileri alanında

¹⁰⁶ Bakınız: Anderson ve McNeil (1992)

ortaya çıkan yeni kavramlar, ağırlıklı olarak bu ilişkinin getirileri olarak ortaya çıkmıştır ve günümüzde bu kavramlar ekonometri alanında en sık kullanılan yöntemlerdir.

İstatistik alanında yaşanan bu gelişmelerin yanında, başka alanlarda da hızlı bir gelişme süreci görülmektedir. Yapay sinir ağları alanı da gelişme gösteren diğer alanlar içinde en belirgin ve potansiyele sahip olanlardan biridir. YSA'lar, günümüzde, diğer bir çok alanda olduğu gibi ekonomi ve istatistik alanlarında da yoğun bir şekilde kullanılmaktadırlar. İstatistik alanında dağılımların belirlenmesi amaçlı, ekonomi alanında ise öngörü amaçlı olarak başarılı bir şekilde kullanılmaktadırlar. Özellikle, zaman serilerinin tahmin edilmesi ve öngörüsü konusunda sıklıkla kullanılıyor olması nedeniyle, YSA'larla İstatistik ve dolayısıyla Ekonomi arasında nasıl bir ilişki olduğunu anlamak önemlidir.

Yapay Sinir Ağları ve İstatistik alanları arasında önemli sayılabilecek bir kesişim kümesi vardır. İstatistik, veri analizi ile uğraşan bir alandır. Benzer şekilde, sinir ağı terminolojisindeki hatalı (noisy) veriden öğrenerek genelleştirme kavramı (veya yeteneği), istatistiksel çıkarım (statistical inference) ile aynı anlamı taşımaktadır. Dolayısıyla, yapay sinir ağları da genelde veri analizi içermektedir. Fakat, bazı sinir ağları veri analizi ile ilgilenmezler ve bu yüzden istatistik alanı ile ilişkileri kısıtlıdır. Örneğin, bazı ağlar öğrenme işlemi içermezler ki Hopfield ve Kohonen ağlar bunlardan bir kaçıdır. Bununla beraber, sinir ağlarının büyük çoğunluğu hatalı veriden genelleme yapabilmeyi öğrenebilmektedir ve bu sayede istatistiksel yöntemlerle benzer ya da aynı oldukları söylenebilir.¹⁰⁷

Bu benzerlik için bir çok örnek gösterilebilir. Mesela, gizli tabaka içermeyen ileri besleme sınıfı ağlar temel olarak genelleştirilmiş lineer modellere karşılık gelirler. Tek bir gizli tabaka içeren ileri besleme sınıfı ağlar ise projeksiyon amaçlı regresyon (projection pursuit regression) ile yakın ilişkiye sahiptirler. Örnekleri artırmak gerekirse, olasılıkçı ağlar temel fark analizine (kernel discriminant analysis) karşılık gelirken, Hebbian öğrenme temel bileşen analizi (principal component analysis) ile oldukça ilişkilidir.

İleri besleme ağlar, doğrusal olmayan regresyon ve ayrıştırma (discrimination) modellerinin oluşturduğu sınıfın bir alt kümesidir. Doğrusal olmayan modeller hakkındaki istatistiksel teorilerden elde edilen bir çok sonuç ileri besleme ağlara uygulanmaktadır.

¹⁰⁷ H.O Stekler, "Are Economic Forecasts Valuable?", Journal of Forecasting, Sayı 13, 1994, s.495-505

Ayrıca, doğrusal olmayan modeller için kullanılan yöntemler, örneğin Levenberg-Marquardt algoritma, ileri besleme ağları eğitmek için kullanılmaktadır.

Sinir ağları algoritmalarına veya uygulamalarına göre tanımlanırken, istatistiksel yöntemler genellikle sonuçlarına göre tanımlanırlar. Örneğin, aritmetik ortalama, basit bir geri yayılma ağ ile kolayca hesaplanabilir. Bunun için, aritmetik ortalama formülünün ağ içinde kullanılması yeterlidir. Sonuçta, hesaplanma şekli ne olursa olsun, çıktı olarak aritmetik ortalama elde edilir. Bu yüzden, bir istatistikçi aynı modeli uygulamak için değişik algoritmalar kullanabilir. Diğer taraftan, bir istatistikçi değişik eğitime kriterlerini değişik istatistiksel özelliklere sahip farklı tahmin yöntemleri olarak görür.

Yapay sinir ağları da istatistiksel modeller gibi dağılıma yönelik varsayımlara ihtiyaç duymaktadır. Fakat, istatistik bilimi bu varsayımların sonuçları ve önem derecesi ile de ilgilenirken, yapay sinir ağları olayın bu yönünü göz ardı etmektedir. Örneğin, en küçük kareler yöntemi hem istatistiksel hem de sinir ağı modellerinde sıklıkla kullanılmaktadır.

Anlatılanların gösterdiği gibi Yapay Sinir Ağları ile istatistik arasında sıkı bir bağlantı kurulabilmektedir. Bu iki alan arasındaki etkileşim YSA tekniğinin bir çok alanda olduğu gibi ekonomi alanında da kolayca uygulama sahası bulmasına yardımcı olmaktadır.

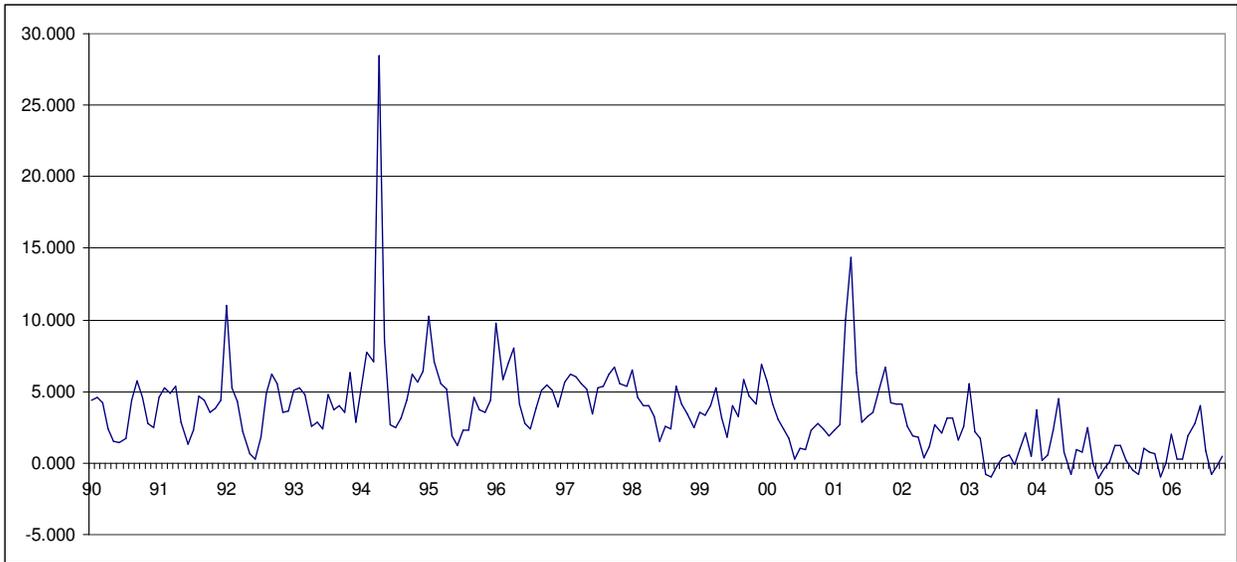
4. MODELLER VE UYGULAMA

Bu bölümde, çalışmada kullanılan modeller tanıtılmaktadır. Çalışma kapsamında, Türkiye ekonomisine ait bir enflasyon oranı değişkeninin tahminine yönelik YSA modeli uygulanacaktır. Bunun yanında, YSA tekniğinin tahmin gücünü karşılaştırabilmek amacıyla iki farklı ekonometrik yöntem kullanarak aynı değişken modellenmektedir. Tahminler elde edilirken, karşılaştırılabilir sonuçlar elde edebilmek amacıyla mümkün olduğunca benzer yapıda modeller kullanılmaya çalışılmıştır.

Tahmin edilecek değişken enflasyon oranı olarak Üretici Fiyat Endeksi (ÜFE) kullanılmaktadır. Bu amaçla, Devlet İstatistik Enstitüsü (DİE) tarafından yayınlanan 1994=100 bazlı seri alınmaktadır. Fakat, bu seri 1994 yılı Ocak ayında başlamaktadır ve bu yüzden kısa bir dönemi kapsamaktadır. Dolayısıyla serinin daha geniş bir dönemi temsil edebilmesi için eski ÜFE (TEFE) serisinden faydalanılmıştır. Bu amaçla, örneklem boyutunun biraz daha genişletilebilmesi amacıyla 1990=100 bazlı eski serinin artış oranları kullanılarak 1994=100 bazlı seri geriye doğru çekilmiştir. Bu sayede, 1990:1 – 2006:10 dönemini kapsayan bir seri elde edilmiştir. Elde edilen aylık fiyat düzeyi serisinin (P) aylık artış oranları kullanılarak modeller oluşturulmuştur. Kullanılan enflasyon oranı serisinin grafiği Grafik 4.1’de sunulmaktadır. Enflasyon oranı modellerinde (ARMA hariç) açıklayıcı değişken olarak döviz kuru artışı ve para arzı artışı kullanılmıştır. Döviz kuru için Merkez Bankası (TCMB) tarafından günlük olarak açıklanan ABD Dolarının (E) aylık ortalamaları tercih edilmiştir. Diğer açıklayıcı değişken olan para arzı için ise yine TCMB kaynaklı geniş para arzı tanımı olan M2Y (M) kullanılmıştır. Belirtilmesi gereken diğer bir nokta ise modelleme yapısı olarak geriye dönük modellemenin kullanılmış olmasıdır. Diğer bir ifadeyle, modeller açıklayıcı değişkenlerin gecikmelerini içermektedir ve bunlara üçüncü açıklayıcı değişken olarak bağımlı değişkenin gecikmesi eklenmektedir. Dolayısıyla, modellemeye dahil edilmeyen diğer açıklayıcı değişkenlerin bağımlı değişkenin gecikmesi ile temsil edildiği varsayılmaktadır. Sonuç olarak, çalışmada kullanılan enflasyon oranı modellerinin genel fonksiyonel gösterimi aşağıdaki gibidir:

$$P = f (P_{-1}, E_{-1}, M_{-1})^{108}$$

Model yapısının belirlenmesinde bazı teorik kısıtlar gözardı edilmiştir. Çünkü, çalışmanın temel amacı, bir politika analizinden ziyade bir performans karşılaştırmasını içermektedir. Bu nedenle, açıklayıcı değişkenlerin belirlenmesinde, değişkenlerin açıklayıcılık gücü ve veri kısıtları öncelikli olarak değerlendirilmiştir. Bu amaca yönelik olarak çeşitli analizler sonucunda, ekonomi teorisinin içerdiği açıklayıcı değişkenler arasından açıklama gücü yüksek olan ve veri kısıtı en az olan değişkenler tercih edilmiştir. Bu sayede, modellerdeki açıklayıcı değişken sayısı da sabit tutulmuştur. Bu nokta modellerin karşılaştırılabilir olması açısından önem arz etmektedir. Çünkü, YSA modelleri sınırsız sayıda açıklayıcı değişken kullanabilmektedir. Oysa, diğer doğrusal yöntemler korelasyon gibi problemler nedeniyle sınırlı sayıda açıklayıcı değişken içerebilmektedir. Bu yüzden, her yöntem için en iyi modeli bulmak yerine belirli bir yapı ile çalışılmıştır.



Grafik 4.1 Aylık Enflasyon Oranı (ÜFE, %)

Kullanılan tahmin yöntemlerinden ilki, bu çalışmanın temel konusu olan Yapay Sınır Ağları tekniğidir. Önceki bölümde de belirtildiği gibi günümüzde YSA'lar bir çok alanda yaygın ve etkin bir şekilde kullanılmaktadır. Ekonomik öngörü de bu alanlardan bir tanesidir. Literatürde özellikle finansal değişkenlerin modellenmesi ve tahmini

¹⁰⁸ Doğal olarak ARMA model bu açıklayıcı değişkenleri içermemektedir.

konusunda bir çok çalışma bulunmaktadır. Bu çalışmalar ağırlıklı olarak döviz kuru ve hisse senedi fiyatlarının tahmin edilmesini konu almaktadır. Bu çalışmalara örnek olarak, döviz kuru için Balkin (2001), El Shazly ve El Shazly (1998) ve hisse senedi piyasası için Leung, Daouk ve Chen (2000) vb. gösterilebilir. Bununla beraber, diğer makro ve mikro ekonomik değişkenlere yönelik çalışmalar da mevcuttur. Beltratti, Margarati ve Terna (1996) YSA'ların ekonomi alanındaki uygulamalarını içeren bir kitap yazmışlardır. Bunun dışında, Tkacz (2001) GSYİH büyümesi için, Heinemann (2000) rasyonel beklentiler için, Church ve Curram (1996) tüketici harcamaları için YSA tekniğini kullanan çalışmalara sahiptirler. Türkçe çalışmalara bakıldığında ise YSA ile ilgili çalışmaların çok fazla olmadığı görülmektedir. Az sayıdaki Türkçe çalışmalar arasında, Yıldız (2001) finansal başarısızlığın öngörülmesinde ve Baylar ve diğerleri (1999) mühendislik alanında YSA'ların kullanımına yönelik çalışmalar olarak sayılabilir. Ayrıca, Altuğ (1994) İMKB'de fiyat öngörüsü, Üngör (1998) döviz kuru tahmini ve Gülseçen (1993) işletme alanlarında YSA kullanımı konusunda çalışmalara sahiptirler. Tüm bu çalışmaların genelinde, YSA'ların (ekonomik) öngörü alanında diğer tekniklere göre daha etkili olduklarına yönelik bulgulara işaret edilmektedir. Bu tür bulguların doğruluk derecesinin Türkiye ekonomisine ait değişkenler için araştırılması da bu çalışmanın kapsamı içinde bulunmaktadır. Bu amaçla, öncelikli olarak fiyat ve üretim değişkenleri için detayları Bölüm 4.3'te açıklanan Geri Yayılmalı İleri Besleme yapısına sahip bir YSA modeli kullanılmıştır. Tahmin edilen YSA modelleri Bölüm 4.1'de açıklanmaktadır.

Tahmin edilen YSA modellerini karşılaştırmak için iki farklı ekonometrik yöntem kullanılmıştır. Bunlar Vektör Otoregresyon (VAR) ve ARMA modelleme teknikleridir. Burada dikkati çeken nokta, doğrusal olmayan modelleme tekniği YSA ile doğrusal modelleme tekniklerinin karşılaştırılıyor olmasıdır. Bu durum bir miktar tezat oluştursa da amaca yönelik bakıldığında en uygun seçenek olduğu görülmektedir. Çünkü VAR ve ARMA ekonometride en yaygın şekilde kullanılan ve öngörü gücü yüksek yöntemlerdir. Bu yüzden karşılaştırma için tercih edilmişlerdir. Buna ek olarak, bu tür bir analiz doğrusal ve doğrusal olmayan yöntemlerin karşılaştırılması olarak da görülebilir ki bu sayede, kesin olmamakla birlikte, değişkenlerin doğrusallık özellikleri hakkında bir takım fikirler elde etmek de mümkün görülmektedir.

Bölümün kalan kısmında tahmin edilen modeller ayrıntılı bir şekilde anlatılmaktadır. Ayrıca, VAR ve ARMA modelleri anlatılırken bu yöntemler için bazı teorik bilgilere de yer verilmektedir. Modellerin karşılaştırılmasına yönelik analizin ayrıntıları ve sonuçları ise bir sonraki bölüme bırakılmaktadır.

4.1. Modeller

Yapay Sinir Ağı modelleri, Bölüm 3.3'te detaylı olarak açıklanan Geri Yayılma Yapay Sinir Ağı metodolojisi kullanılarak tahmin edilmiştir. İleri besleme ağ yapısına sahip bu ağ mimarilerinde yönlendirmeli eğitime kullanılmaktadır. Zaten, Geri Yayılma Ağı olarak adlandırılmalarının temel sebebi de bir yönlendirmeli eğitime tekniği olan geri yayılma algoritması kullanılmasıdır.

Bu yöntem, kantitatif verilerle öngörü amaçlı çalışmalarda en çok kullanılan ağ mimarisi olması nedeniyle bu çalışmada tercih edilen metot olmuştur. Hem doğrusal hem de doğrusal olmayan yapılarda oldukça başarılı sonuçlar vermesi öngörü amaçlı çalışmalarda sıkça kullanılmasının ve dolayısıyla bu çalışmada uygulanan metot olmasının en temel sebeplerinden birisidir. Başka bir önemli sebep ise diğer mimarilere göre çok daha kullanışlı bir yöntem olmasıdır. Bu sayede daha az çaba ile yeterli derecede başarılı sonuçlar elde edebilen bir mimari olarak dikkat çekmektedir.

Fiyat modeli (YSA) tahmininde tam bağlantılı ve iki tabakalı ağ mimarisi oluşturulmuştur. Dolayısıyla, ağ mimarisi tek gizli tabakaya sahiptirler. Ayrıca, uygulanan model için de eğitime sürecinde öğrenme kuralı olarak Delta Kuralına yer verilmiştir. Girdi ve çıktı tabakalarındaki nöron sayılarının normal olarak girdi ve çıktı değişkenlerin sayısına bağlı olduğu göz önüne alındığında, sadece gizli tabakanın sahip olduğu nöron sayısı için herhangi bir kısıt kullanılmamıştır.

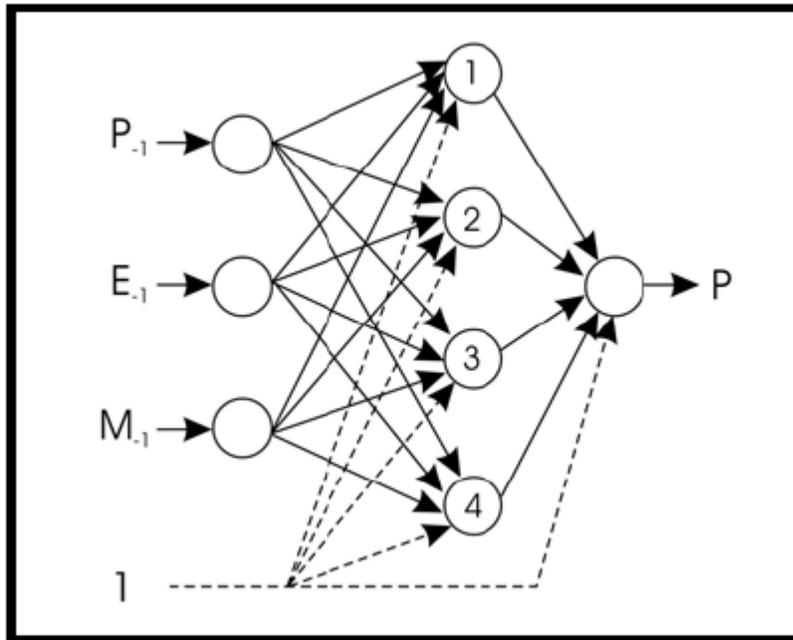
Bundan sonraki bölümde YSA metodolojisi ile tahmin edilen fiyat modeli açıklanmaktadır. Hem oluşturulan model mimarisi hem de elde edilen sonuçlara yer verilmektedir. Bu model tahminleri MATHCAD yazılımının Sinir Ağları Alt Yazılımı (Neural Network Toolbox) kullanılarak gerçekleştirilmiştir.

4.1.1. YSA Modeli

Fiyat modelinde bağımlı değişken olarak kullanılan genel ÜFE serisinin aylık artış oranlarını açıklamak için döviz kuru (ABD Doları) ve M2Y para arzı tanımının aylık artış oranları ile birlikte bağımlı değişkenin birinci gecikmeleri kullanılmıştır. Dolayısıyla, bu

tercihlerin ima ettiği fonksiyonel yapı üç girdi değişkenine (P_{-1} , E_{-1} , M_{-1}) ve bir çıktı değişkenine (P) sahiptir. Büyük harflerle gösterilen bu değişken isimleri, değişkenlerin doğal logaritmali birinci farklarını temsil etmektedir ve aksi belirtilmedikçe bütün modellerde bu gösterim kullanılmıştır.

Üç girdi değişkeni ve bir çıktı değişkeni içeren bu fonksiyonel yapıyı tahmin etmek için iki tabakalı bir Geri Yayımlı YSA mimarisi (YSA) oluşturulmuştur. Şekil 4.1’de sunulan bu mimarinin girdi tabakasında girdi değişkenlerin değerlerinin ağa sunulmasını sağlayan üç adet nöron ve çıktı tabakasında ise bağımlı değişkene ait ağ çıktısının alındığı bir adet nöron bulunmaktadır.



Şekil 4.1: YSA Modelinin Mimarisi

Önceden de belirtildiği gibi, gizli tabakadaki nöron sayısı için bir kısıt kullanılmamıştır. Bunun yerine, gizli tabakadaki nöron sayısı, üst limit kriteri de dikkate alınarak, bir performans değerlendirmesine göre belirlenmiştir. Değişik sayıda gizli nöronlarla yapılan denemeler sonunda gizli tabakadaki nöron sayısı dört olarak belirlenmiştir. Şekil 4.1’de gizli nöronlar numaralandırılmış dairelerle gösterilmektedir. Ayrıca, hem gizli tabaka hem de çıktı tabakası için rassal hata terimi kullanılmıştır. Bu terim de yukarıdaki şekilde kesikli çizgilerle gösterilmektedir.

YSA modelinde, ağ mimarisinin yapı taşları olan nöronların kullandığı toplama fonksiyonu olarak doğrusal toplama işlemi tercih edilmiştir. Tabakaların çıktı değerlerini hesaplayan transfer fonksiyonu olarak ise gizli tabakada ve çıktı tabakasında farklı fonksiyonlara yer verilmiştir. Gizli tabakalardaki nöronlarda hiperbolik tanjant fonksiyonuna yer verilirken, çıktı tabakasındaki nöronda ise doğrusal transfer fonksiyonu kullanılmıştır. Gizli tabakanın içerdiği nöron sayısının belirlenmesine benzer şekilde tabakalarda kullanılacak transfer fonksiyonlarının belirlenmesinde de bir performans değerlendirmesinin sonuçları dikkate alınmıştır. Sonuç olarak, tahmin edilen YSA modelinin fonksiyonel gösterimi şu şekildedir:

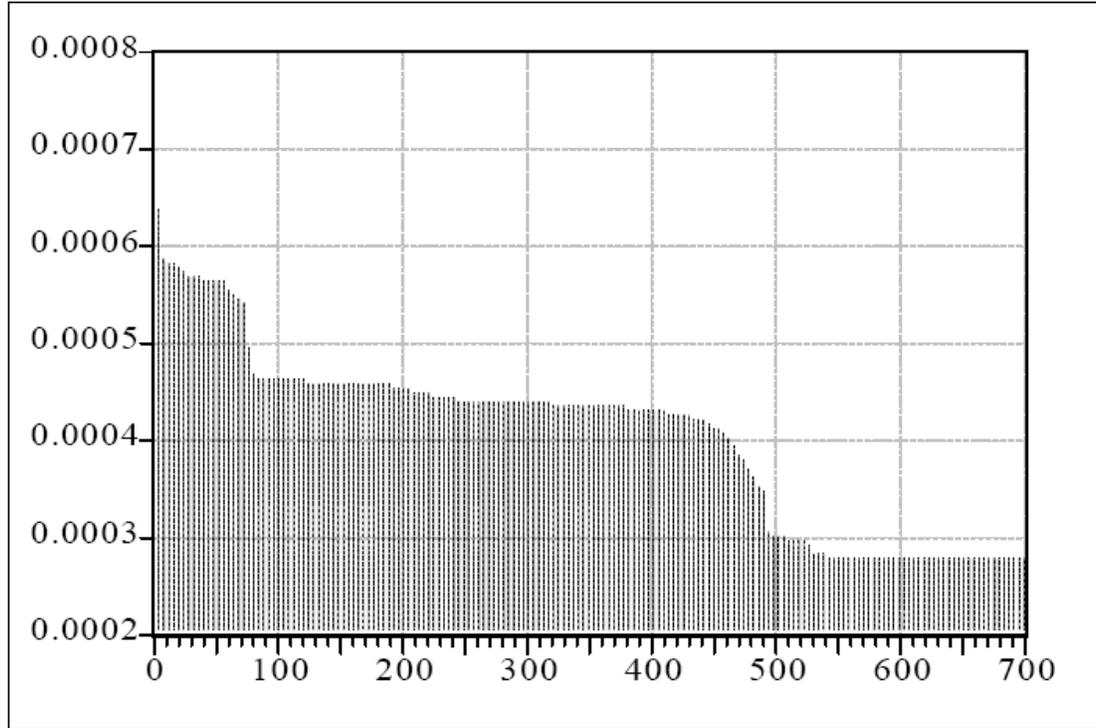
$$P_t = \left(\alpha_2 + \sum_{j=1}^4 w_{2j} \cdot \tanh \left(\alpha_1 + \sum_{i=1}^3 w_{1i} X_{i,t-1} \right) \right) \quad (7)$$

Denklemlerde P fiyat değişkenini; w_1 gizli tabaka için, w_2 çıktı tabakası için bağlantı ağırlıklarını; α_1 gizli tabaka için, α_2 çıktı tabakası için sapma değerlerini; X ise değişken vektörünü ($X_1=P$, $X_2=E$, $X_3=M$) ifade etmektedir.

Modelin mimarisi oluşturulduktan sonra eğitme sürecine geçilmiştir. Ağın öğrenme işlemini gerçekleştirdiği bu sürecin başlangıcında, bağlantı ağırlıkları rassal bir şekilde belirlenmiştir. Eğitme süreciyle birlikte amaç fonksiyonunun (Ortalama Hata Kareleri Toplamı - MSE)¹⁰⁹ minimize edilebilmesi için bağlantı ağırlıklarının ayarlanması (öğrenme) işlemi gerçekleştirilmiştir. Eğitme süreci için Ocak 1990 ile Ekim 2006 arasındaki dönem aralığını kapsayan örneklem seti içinden (Ocak 1990 – Aralık 1999) kullanılmıştır ve bu dönem için amaç fonksiyonu olarak alınan MSE fonksiyonunu minimize eden bağlantı ağırlıkları seti araştırılmıştır.

YSA modeli 700 döngü (epoch) kullanılarak eğitilmiştir ve MSE fonksiyonunun bu eğitme işlemi boyunca nasıl minimize edildiği Grafik 4.3'te sunulmuştur. Grafikten görüldüğü gibi, eğitme işlemi sayesinde MSE değeri, ilk 5-10 döngüde oldukça hızlı olmak üzere, giderek azalmış ve 0.00027 civarında sabitlenmiştir. Grafikte, rassal olarak belirlenen başlangıç bağlantı ağırlıklarının im ettiği MSE değeri gösterilmemiştir çünkü doğal olarak, bu noktadaki MSE değeri oldukça büyük bir değere sahiptir.

¹⁰⁹ YSA modellerinde amaç fonksiyonu olarak Ortalama Hata Kareleri (Mean Squared Errors) kullanılmıştır.

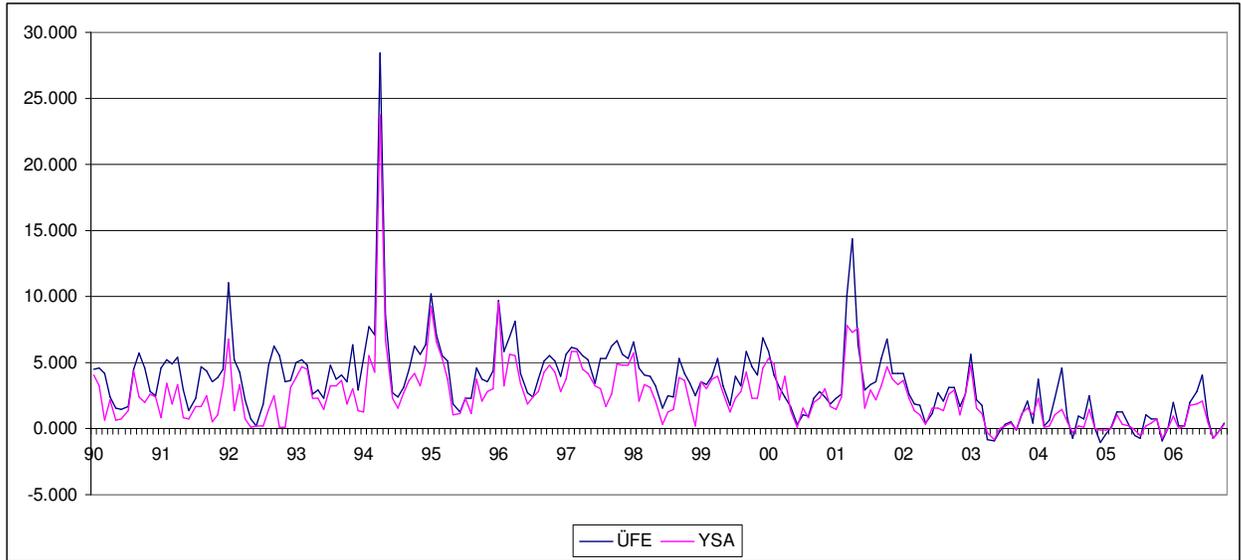


Grafik 4.2: Eğitim Süreci İçinde MSE'nin Değerleri

Bağlantı ağırlıklarının ayarlanması, yani eğitim işleminin tamamlanması ile birlikte YSA modelinin tahmin süreci de tamamlanmıştır ve tahmin edilen model simüle edilerek öngörüler alınmıştır. YSA modelinin eğitim setine göre örneklem içi (in-sample) ve dışı (out-sample) öngörülerini gerçekleştirme değerleriyle karşılaştırmalı olarak Grafik 4.3'te sunulmuştur¹¹⁰. Grafikte örneklem dışı dönem gölgeli alan kullanılarak belirgin hale getirilmiştir. Öncelikli olarak belirtilmesi gereken nokta bir aşırı eğitim sorunuyla karşılaşmadığıdır. Bu ifadeyi örneklem dışı öngörülere bakarak doğrulamak mümkün gözükmemektedir çünkü test setine ait öngörülerde bir ıraksama problemi görülmemektedir. Grafiğe bakıldığında, YSA modelinin gerek örneklem içi gerekse örneklem dışı öngörüler açısından oldukça başarılı bir performansa sahip olduğu söylenebilmektedir. Özellikle, örneklem dışı dönemde, yani modelin tahmininde kullanılmayan gözlemlere ait öngörülerdeki başarısı dikkat çekicidir. Ayrıca, model 1994 krizini beklenmedik derecede başarılı bir şekilde yakalayabilmiştir. Bunu sağlayan mekanizma olarak, döviz kuru ve para arzı değişkenlerinin gecikmeli etkilerinin yanında bir yakınsama sağlayan eğitim

¹¹⁰ Modeller eğitim seti kullanılarak tahmin edildiğinden dolayı örneklem içi ile eğitim seti dönemi (Ocak 1990 – Aralık 1999), örneklem dışı ile test seti dönemi (Ocak 2000 – Ekim 2006) ifade edilmektedir.

işlemi gösterilebilmektedir. Hemen belirtilmelidir ki modelde herhangi bir kukla veya mevsimsel değişken kullanılmamıştır. Buna rağmen 1994 krizinin ve mevsimsel etkilerin model tarafından kavranabildiği görülmektedir. Dolayısıyla, basit bir şekilde oluşturulmasına rağmen, YSA modeli oldukça başarılı bir performans sağlamıştır.



Grafik 4.3: YSA Modeli Öngörülleri (%)

4.1.2. VAR Modeli

Yapay Sinir Ağları metodolojisi ile tahmin edilen modellerin öngörü gücünü karşılaştırmak için kullanılacak zaman serileri tekniklerinden ilki ‘Vektör Otoregresyon (VAR – Vector Autoregression)’ tekniğidir. VAR modelleri herhangi bir zaman noktasında, zamana bağlı serilerin tahminini sağlayan bir model olarak tanımlanabilir. İstatistiksel olarak güçlü bir yöntemdir.

Vektör otoregresif modelleme tekniği ilk olarak Sims (1980) tarafından yapısal eşanlı denklem sistemlerinin teorik sebeplere dayalı kısıtlarını göz ardı edebilecek bir yaklaşım olarak ortaya atılmıştır.¹¹¹ Bu yeni metodolojinin temel farklılığı sıfır kısıtlarının kullanılmaması, dolayısıyla modelin temelinde ekonomik teoriye bağlı sınırlamalar bulunmamasıdır. Bunun anlamı, VAR modelinin tamamen kullanılan verilerin özelliklerine göre oluşturulduğudur. Bu söylem ilk bakışta ekonomik tezinin VAR

¹¹¹ G.E.P. Box, ve G . Jenkins, Time Series Analysis: Forecasting and Control, Holden Day, San Fransisco, 1970, s.168

modelleme tekniği için önemsiz olduğunu düşündürebilmektedir. VAR modelleme tekniğinde ekonomik teorinin önem taşıdığı tek nokta modeli oluşturacak değişkenlerin seçilmesi aşamasıdır. Bu da aslında VAR modellemesinin ekonomik teoriden tamamen bağımsız olmadığına bir göstergesidir.

VAR modelleme tekniğinin ilk adımı genel (kısıtsız) bir vektör otoregresif modelin formüllemesidir. Adından da anlaşılacağı gibi bu adım modeldeki her değişkenin tüm değişkenlerin belirli sayıdaki gecikmeli değerleri ile ilişkilendirilmesini içermektedir. Genel olarak, n sayıda değişken ve n sayıda gecikme içeren basit bir kısıtsız VAR model aşağıdaki gibi gösterilmektedir:¹¹²

$$y_{i,t} = A_1 * y_{i,t-1} + \dots + A_n * y_{i,t-n} + B * x_t + \varepsilon_t ; i=1, 2, \dots, n \quad (8)$$

Bu gösterimde y içsel değişkenler vektörünü, x dışsal değişkenler vektörünü, A ve B tahmin edilecek katsayı matrislerini, ε hata (innovations) vektörünü ve t ise zaman operatörünü temsil etmektedir.

Yukarıdaki model aslında yapısal bir modelin kısıtsız indirgenmiş bir halidir. Bu yüzden, katsayılar üzerinde kısıtlamalar uygulanmadığında çok değişkenli en küçük kareler (multivariate least squares) tahminleri sıradan (ordinary) en küçük kareler tahminlerinden daha etkili değildirler (Harvey, 1989). Bir genel VAR modelinin belirli denklemleri bazı deterministik bileşenler kümesi (örneğin sabit terim, deterministik trend, mevsimsel kukla değişkenler vb.) ile desteklenirler. Ayrıca, stokastik trend bileşeninin varlığı durumunda, gerekli düzeltme işlemleri sonrasında, ilgili değişkenler de modele eklenebilmektedir.

Kısıtsız VAR modellerinin en yoğun şekilde kullanıldığı amaçların en önemlilerinden birisi öngörü (forecast) çalışmalarıdır. VAR model kullanılırken modelin temelini oluşturan ekonomik teoriye tam olarak bağlı kalmak gibi bir sorun yoktur. Bundan dolayı, VAR tekniği birbirleri ile ilişkili olduğu bilinen zaman serilerine yönelik öngörü sistemleri için kullanılmaktadır. Ayrıca, VAR modeller literatürde en etkili öngörü yöntemlerinden birisi olarak genel kabul görmüş bulunmaktadır.

¹¹² W. Enders. Applied Econometric Time Series, John Wiley & Sons Inc. 1995. S.289

Modelin içerdiği denklemlere ait hata terimleri arasındaki eşanlı korelasyonun göz ardı edildiği varsayımı altında, VAR modelin öngörüsü mekanik bir şekilde elde edilebilir. İlk öngörü dönemi için, öngörüler değişkenlerin son gözlem değerlerine bağlı olarak oluşturulmaktadır:

$$y_{i,t+1}^f = A_1 * y_{i,t-1+1} + \dots + A_n * y_{i,t-n+1} + B * x_{t+1} ; i=1, 2, \dots, n \quad (9)$$

Bu gösterimde, y^f , y değişkeninin (değişken vektörünün) gerçekleşme değerlerinin bilinmediği dönemler için elde edilen öngörüler kullanılarak sırasıyla hesaplanan gelecek dönemlere ait öngörülerini temsil etmektedir. Başka bir şekilde göstermek gerekirse;¹¹³

$$y_{i,t+j}^f = A_1 * y_{i,t-1+j} + \dots + A_n * y_{i,t-n+j} + B * x_{t+j} ; i=1, 2, \dots, n \quad (10)$$

Denklemler-10 şeklinde yazılabilir ve burada¹¹⁴

$$y_{i,t-n+j}^f = \begin{cases} y_{i,t-n+j}^f & ; j > n \\ y_{i,t-n+j} & ; j < n \end{cases} \quad (11)$$

Bu özellikleriyle, modelleme ve öngörü tekniği olarak büyük avantajlar sağlayan VAR modelleri son yıllarda durağanlık (stationarity) ve ko-entegrasyon (co-integration) gibi zaman serileri alanında ortaya çıkan gelişmelerin de yardımıyla oldukça yaygınlaşmıştır. Günümüzde, ekonomi alanında da sıkça kullanılmakta olan bu yöntem özellikle öngörü amaçlı çalışmalar için uygun olan, istatistiksel olarak güçlü bir modeldir. Bu yüzden, öngörü performansı karşılaştırmasında performans kriteri sağlayabilecek bir teknik olarak bu çalışmada tercih edilmiştir.

¹¹³ W. Enders. Applied Econometric Time Series, John Wiley & Sons Inc. 1995. S.290

¹¹⁴ W. Enders. Applied Econometric Time Series, John Wiley & Sons Inc. 1995. S.290

4.1.2.1. VAR Modeli Uygulaması

Çalışmada fiyat modeli için kullanılan fonksiyonel yapı Bölüm 4'ün başında açıklanmıştır. Üç değişken (P: Üretici Fiyat Endeksi, E: ABD Doları Döviz Kuru ve M: M2Y Para Arzı) içeren bu yapı ile tahmin edilen VAR modelinin (VAR) genel yapısı şu şekilde gösterilebilir:

$$\text{VAR} = f(\text{P}, \text{E}, \text{M})$$

VAR modeli içerdiği değişkenlerin durağan halleri kullanılarak tahmin edilmiştir. İlgili değişkenlerin doğal logaritmalı düzey değerleri üzerinden yapılan durağanlık testleri Tablo 4.1'de sunulmuştur. Durağanlık testleri Geliştirilmiş Dickey Fuller Testi (ADF – Augmented Dickey-Fuller Test)¹¹⁵ kullanılarak yapılmıştır. ADF testlerinde trend kullanılmamıştır ve gecikme seçimi, yüksek dereceli otokorelasyonu test edebilecek şekilde, kullanılacak gecikmelerin anlamlılık düzeylerine göre belirlenmiştir. Tablonun sunduğu ADF test sonuçları tüm değişkenlerin I(1) seri özelliği taşıdığını; yani birinci farkları alındığında durağan hale geldiklerini göstermektedir. Bundan dolayı, model doğal logaritmalı değişkenlerin birinci farkları kullanılarak tahmin edilmiştir.

Tablo 4.1: Fiyat Modeli Değişkenlerine Ait Durağanlık Testleri

Değişken	Gecikme	ADF İstatistiği	
		Düzye	Birinci Fark
P	1	0.77	-7.46
E	1	1.15	-8.57
M	2	2.23	-7.26
%1 Kritik Değer: -3.47			
%5 Kritik Değer: -2.87			
%10 Kritik Değer: -2.57			

¹¹⁵ ADF testi ile ilgili ayrıntılar için bkz. Dickey ve Fuller (1979) ve Enders (1995)

Ayrıca, tahmin edilen VAR modeline mevsimsel etkilerin yakalanabilmesi için (mevsimsel etkilerin deterministik olduğu varsayımı kullanılarak) dışsal olarak mevsimsel kukla değişkenler eklenmiştir. Bunun yanında, 1994 krizine yönelik bir kukla değişken de dışsal olarak modele dahil edilmiştir. Bu değişkenleri içeren bir kısıtsız VAR modeli eğitim seti dönemine ait veriler kullanılarak tahmin edilmiştir. Diğer taraftan, modellerin karşılaştırılabilir yapılarda tahmin edildikleri daha önce belirtilmişti. Bu anlamda, VAR modeli de tek gecikmeli olarak tahmin edilmiştir. Fakat, bilgi kriterlerine göre bir gecikme belirleme analizi yapıldığında, modelin tek gecikmeli olarak tahmin edilmesinin çok tutarsız olmadığı görülmüştür. Çünkü, Akaike Bilgi Kriteri iki gecikmeyi işaret ederken, Schwarz Kriteri tek gecikmeyi göstermiştir. Bu iki kriterden hangisinin tercih edilmesi gerektiği sorusu zaten bir belirsizlik taşımaktadır ve genellikle araştırmacıya kalmaktadır. Bu modelde Schwarz Kriteri ile tutarlı bir gecikme yapısı kullanılmıştır. Tahmin edilen VAR modeli Tablo 4.2’de sunulmuştur.

Tablo 4.2: VAR Modeli Tahminleri

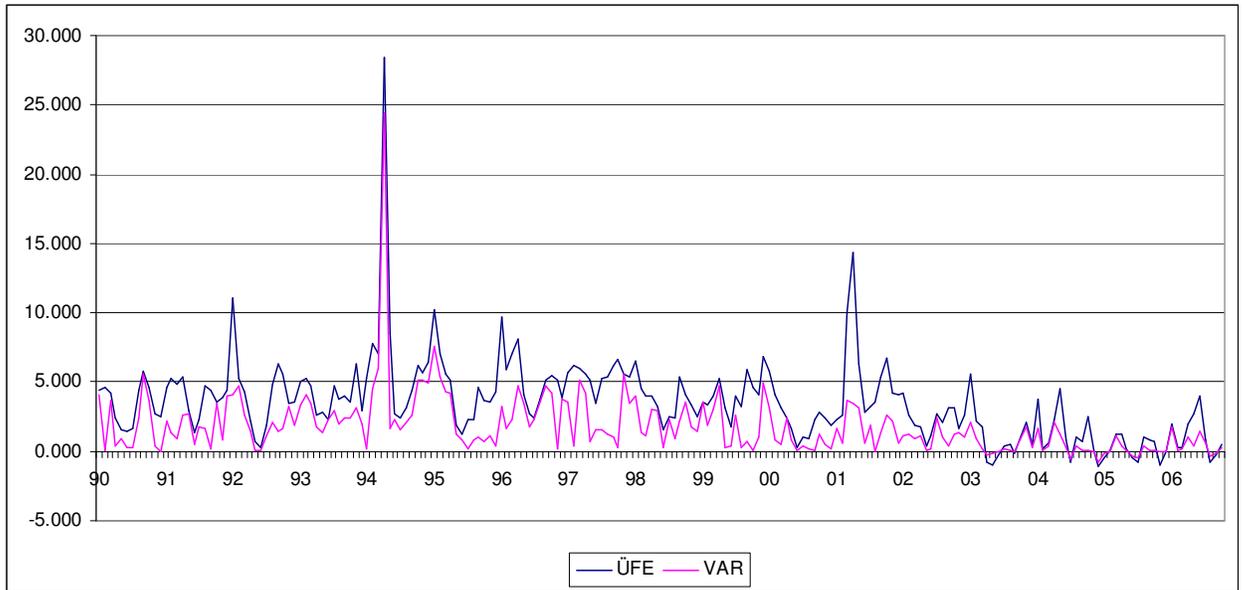
Değişken	P	E	M
	0.328	-0.185	0.052
P(-1)	(0.070)	(0.113)	(0.069)
	(4.629)	(-1.626)	(0.755)
	-0.012	0.248	-0.047
E(-1)	(0.039)	(0.063)	(0.038)
	(-0.310)	(3.926)	(-1.245)
	0.048	0.023	0.421
M(-1)	(0.076)	(0.122)	(0.074)
	(0.640)	(0.188)	(5.656)
Sabit	0.664	0.949	0.614
Terim	(0.070)	(0.113)	(0.068)
	(9.411)	(8.391)	(8.958)
Kukla	0.233	0.498	0.152
Değişken	(0.016)	(0.026)	(0.015)
	(14.197)	(18.89)	(9.510)
R^2	0.724	0.764	0.524
HKT ¹¹⁶	0.036	0.092	0.034
F-istatistiği	26.325	32.452	11.008
Akaike Bilgi Kriteri			-15.447
Schwarz Kriteri			-14.547

Tabloda, her değişken için tahmin edilen katsayılar gösterilmiştir. Bu katsayıların altında parantez içinde verilen rakamların ilki standart hata değerini ikincisi ise t-istatistiği değerini göstermektedir. Mevsimsel kukla değişkenler tabloya dâhil edilmemiştir. Modelin içerdiği denklemlere ait R^2 , Hata Kareleri Toplamı (HKT) ve F-istatistiği değerlerine yer verilirken, tablonun son bölümünde modelin geneline ait bilgi kriterleri sunulmuştur. Modelin genelini değerlendirebilmek açısından etki-tepki (impulse-response) analizine

¹¹⁶ Hata Kareleri Toplamı – Sum of Squared Residuals

bakıldığında model oldukça başarılı gözükmektedir. Diğer taraftan, modelin fiyat öngörülerinin kullanılacağı düşünülerek ayrıca fiyat denkleminde bakıldığında R^2 ve HKT değerlerinin tatmin edici bir düzeyde oldukları söylenebilmektedir. VAR modelinden elde edilen öngörüler aşağıdaki grafikte sunulmuştur.

VAR modeli eğitime setinin içerdiği yapıyı başarılı bir şekilde yakalayabilmiştir. Özellikle, 1994 krizini yakaladığı görülmektedir fakat bu durum büyük ölçüde kukla değişken kullanılmasından kaynaklanmıştır. Bununla birlikte, kukla değişken olmadan bir tahmin alındığında da büyük ölçüde 1994 krizi tahmin edilebilmektedir. Model öngörülerini, yeni verilerle öngörü alınan test dönemine bakıldığında ise modelin başarısı biraz zayıflamaktadır. Özellikle, Şubat 2001 krizinin etkilerini, bu dönemde kur politikasındaki değişim nedeniyle bir yapısal değişim mevcuttur, tahmin etmekte oldukça başarısız gözükmektedir.



Grafik 4.4: VAR Modeli Öngörülerini (%)

4.1.3. ARMA Modeli

Otoregresif Hareketli Ortalama (ARMA – Autoregressive Moving Average) modellere ait metodoloji ilk olarak Box ve Jenkins (1970) tarafından geliştirilmiştir. Bu yüzden, ARMA modeller literatürde Box-Jenkins modeller olarak da adlandırılmaktadırlar. Genel bir ARMA(p,q) modelinin, yani p dereceden otoregresif

(AR) ve q dereceden hareketli ortalama (MA) yapısına sahip bir genel ARMA modelinin fonksiyonel gösterimi aşağıdaki gibidir.

$$X_t = \phi_1 X_{t-1} + \dots + \phi_p X_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q} \quad (12)$$

Bu gösterimde $\{\varepsilon_t\}$ serisi sıfır ortalama ve σ^2 varyansa sahip iid¹¹⁷ bir $[\varepsilon_t \sim \text{iid } N(0, \sigma^2)]$ taşımaktadır. Tüm θ_i katsayılarının sıfır olması durumunda bir AR(p) model ve tüm ϕ_i katsayılarının sıfır olması durumunda ise bir MA(q) model elde edilir. AR ve MA modellere benzer şekilde, ARMA modeller serilerin ortalamadan sapmalarını temsil etmek için kullanılmaktadırlar. Örneğin, bir serinin \bar{X} ortalamaya ve AR(1) yapısına sahip olması durumunda, bu yapı

$$(X_t - \bar{X}) = \phi(X_{t-1} - \bar{X}) + \varepsilon_t \quad (13)$$

şeklinde gösterilebilir. Bu gösterim X_t için yazıldığında, sabit terimin ortalama değeri kapsadığını gösteren aşağıdaki fonksiyon elde edilir.

$$X_t = (1 - \phi)\bar{X} + \phi X_{t-1} + \varepsilon_t \quad (14)$$

ARMA modellerin oluşturulmasında ilk adım serilerin durağanlık ve mevsimsellik özelliklerinin belirlenmesidir. Serilerin durağan olmaması durumunda, fark alma (differencing) işlemi ile durağanlık sağlanabilmektedir. Ayrıca, Box-Jenkins modellemesi çerçevesinde, bir uyarlanmış (fitted) seri üretilip gerçek seriden farkının alınmasını içeren bir yöntem de kullanılmaktadır. Hemen belirtmelidir ki durağan olmayan bir serinin d kere farkı alınarak durağan hale getirilerek tahmin edilen bir ARMA(p,q)¹¹⁸ modeli literatürde ARIMA(p,d,q)¹¹⁹ model olarak adlandırılmaktadır. Modellenmesi gereken bir mevsimsellik bileşeninin bulunması durumunda ise mevsimsel fark alma işlemi,

¹¹⁷ "iid" terimi benzer şekilde bağımsız dağıtılmış (independently distributed) anlamında kullanılmaktadır.

¹¹⁸ ARMA modeller hakkında daha detaylı için bkz. Box ve Jenkins (1970), Hamilton (1994), Gujarati (1995) ve Janacek ve Swift (1993)

¹¹⁹ ARIMA (Autoregressive Integrated Moving Average) durağan olmayan ARMA modelin özel bir halidir.

mevsimsel AR ve MA terimlerinin kullanılması veya mevsimsel kukla değişkenler kullanılması gibi alternatif yollara başvurulabilmektedir. Bunun dışında, mevsimsellik ve durağanlık gibi, trend bileşeni de bu yöntemde önem taşır. Mevsimsellik ve trend kavramlarının stokastik ve/veya deterministik olmalarına göre farklı işlemlere gerek duyulabilmektedir.

Durağanlık ve mevsimsellik şartlarının sağlanmasından sonraki adım AR ve MA yapılarının derecelerinin (p ve q) belirlenmesini içermektedir. Bu işlemin temel aracı ise otokorelasyon (veya kısmi otokorelasyon) analizidir.

Box-Jenkins öngörü modelleri istatistiksel kavramlar ve ilkeler üzerinde inşa edilirler ve çok çeşitli zaman serileri yapılarını modelleyebilirler. Ayrıca, doğru modelin tanımlanabilmesi için sistematik bir yaklaşım içerirler. Hem modelin geçerliliğini doğrulamak hem de öngörü gücünü ölçmek için istatistiksel kavramlar vardır. Durağan seriler eldeleyen artık temel model tanımlanabilir. Üç temel model (AR, MA ve ARMA) vardır ve bu çalışmada bu temel modellerden uygun olanı kullanılmaktadır.

Zamana bağlı bir veri setinin geçmiş değerlerini kullanarak doğruluk derecesi yüksek öngörüler sağlayabilen bu yöntem, istatistik ve ekonomi (ekonometri) alanlarında önemli bir yere sahiptir. Bu yüzden, YSA metodolojisi için öngörü karşılaştırmasında kullanılacak ikinci yöntem olarak tercih edilmiştir. Bu amaçla, fiyat ve üretim değişkenlerinin tahmini için Box-Jenkins modeller tahmin edilmiştir. Fakat, model tahmininde p ve q değerlerinin metodoloji çerçevesinde belirlenmesi yerine, diğer modellerin fonksiyonel yapısı ile karşılaştırılabilir olduğu düşünülen $p=1$ ve/veya $q=1$ yapısı kullanılmıştır.

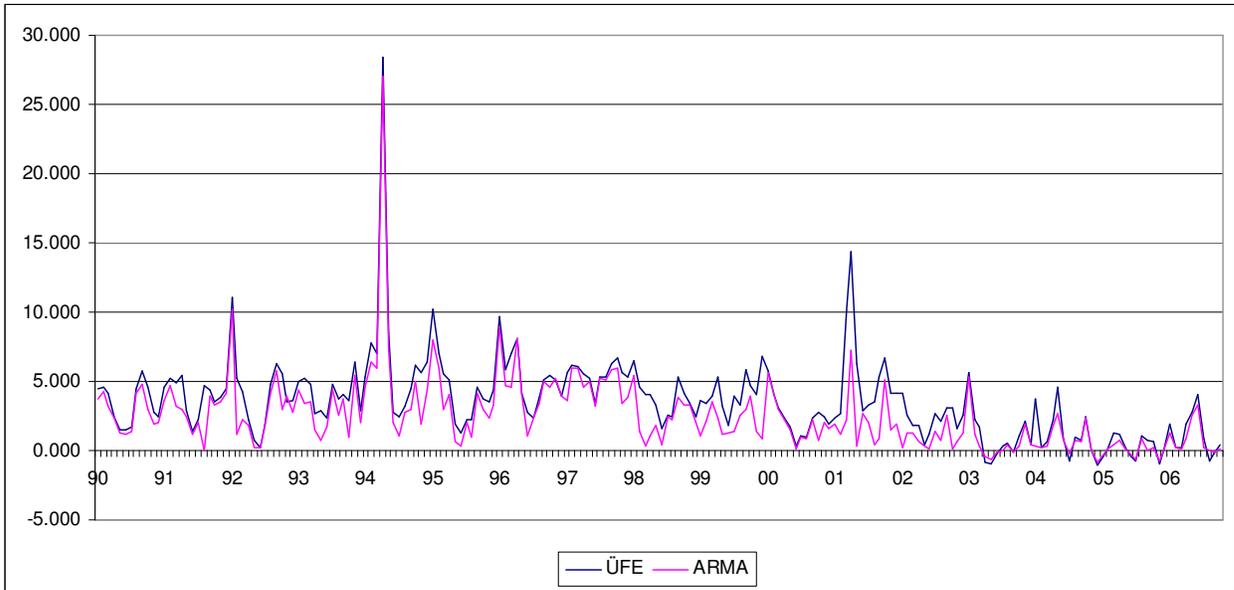
4.1.3.1. Arma Modeli Uygulaması

Box-Jenkins modellerin durağan seriler kullanılarak oluşturulduğu gerçeği doğrultusunda, öncelikle fiyat serisinin durağanlık düzeyinin belirlenmesi gerekmektedir. VAR modelinin anlatıldığı bölümde gerçekleştirilen ADF testlerinden doğal logaritmalı düzey fiyat serisinin I(1) yapısına sahip olduğu belirlenmişti. Bu yüzden, fiyat değişkeni için Box-Jenkins modelinin tahmininde durağan bir yapı içeren birinci farkı alınmış doğal logaritmalı fiyat serisi kullanılmıştır. VAR modeline benzer şekilde mevsimsel kukla değişkenler ve 1994 krizine yönelik bir kukla değişkenle birlikte ARMA modeli tahmin edilmiştir. Modelin tahmin sonuçları aşağıdaki tabloda sunulmuştur (Tablo 4.3).

Tablo 4.3: ARMA Modeli Tahminleri

Bağımlı Değişken: P				
Değişken	Katsayı	Std. Hata	t-istatistiği	Olasılık
Sabit Terim	1.046	0.002	399.420	0.000
S1	0.017	0.003	4.603	0.000
S5	-0.012	0.004	-2.864	0.004
S6	-0.032	0.004	-6.619	0.000
S7	-0.018	0.004	-3.829	0.000
S8	-0.012	0.004	-2.939	0.003
Kukla Değ.	0.208	0.013	14.883	0.000
AR(1)	0.487	0.069	7.042	0.000
R^2	0.714	Regresyon Std. Hata		0.015
HKT	0.037	F-istatistiği		56.512
D-W İstatistiği	2.022	Olasılık (F-ist.)		0.000
Ters AR Kökleri	0.49			

Öncelikle belirtmelidir ki model eğitime seti verileri ile ARMA(1,1) yapısında tahmin edilmiştir. Fakat, otokorelasyon (ve kısmi otokorelasyon) analizlerine göre tutarlı bir model değildir. Bununla birlikte, $p=1$ ve $q=1$ yapısı sayesinde hem karşılaştırılabilir bir model elde edildiği düşünülmektedir hem de öngörüler açısından veri kaybı önlenmiş olmaktadır. Bunlara ek olarak, tablodan görüleceği gibi birinci dereceden MA yapısı fiyat değişkeni için anlamsız (katsayısı istatistiksel olarak sifıra eşit) kalmıştır. Bu durumda, ARMA modeli olarak isimlendirilmeye devam etmekle birlikte bir AR(1) modeli elde edilmiştir. Tablodaki 'S' değişkenleri mevsimsel kukla değişkenleri göstermektedir. Model diagnostik problem içermemektedir ve bu model kullanılarak Grafik 4.5'da sunulan öngörüler oluşturulmuştur.



Grafik 4.5: ARMA Modeli Öngörüleri (%)

Fiyat modeli hem eğitim seti hem de test seti için oldukça başarılı öngörüler sağlamıştır. Serinin genel yapısının model tarafından tutarlı bir şekilde tanımlanabildiğini söylemek mümkündür. Büyük değişimler içeren noktalarda, değişimin büyüklüğü tam olarak yakalanamamış olsa da değişimin yönü doğru olarak tahmin edilebilmiştir. Kukla değişken kullanılması nedeniyle 1994 krizinin tam olarak yakalanmış olması normal karşılanmalıdır. Kukla değişkenin kullanılmadığı durumda ise 1994 krizinin etkisi için en azından yön olarak tutarlı bir sonuç alınabilmektedir. 2000 yılı başında uygulamaya konulan IMF destekli stand-by programının getirdiği fiyat düşüşünü yakalamış olması, bu tür modellerin öngörü açısından güçlü yöntemler olduklarının bir göstergesidir. Buna rağmen 2001 krizinde artış yönünün tahmin etmekle birlikte 1994 yılında gösterdiği başarıyı elde edemediğini görmekteyiz.

5. ÖNGÖRÜ DEĞERLENDİRMESİ & MODEL KARŞILAŞTIRMASI

Öngörü (forecasting) modellemesi alanı bilinmeyi tahmin etmek için kullanılan yöntemlerle ilgilidir. Genel olarak, bilinmeyen geleceği tahmin etmek (zaman serileri öngörüsü) için kullanılmakla birlikte panel (cross-sectional) veri setleri için de uygulama alanı bulmaktadır. Bu alan kantitatif (istatistiksel) yöntemler kadar karar yöntemlerine ait çalışma ve uygulamaları da içermektedir.

Öngörü modellemesi, diğer bir çok alan gibi, ekonomi alanı için büyük bir önem taşımaktadır ve oldukça yaygın bir şekilde kullanılmaktadır. Ekonomik birimlerin karar mekanizmalarını oluşturmalarından makroekonomik politikaların oluşturulmasına ve değerlendirilmesine kadar çok sayıda ekonomik aktivite öngörü modellemesinden faydalanmaktadır. Örneğin, son dönemlerde giderek artan oranda önem kazanan rasyonel bekleyişler teorisinin ortaya koyduğu ileriye dönük (forward-looking) bekleyişler, öngörü modellemesinin ekonomi alanındaki önemini daha da artırmıştır.

Öngörü modellemesinin ekonomi ve finans alanlarındaki öneminin temel sebebi karar mekanizmasında önemli rol oynamasıdır. Basit bir şekilde, iyi öngörüler iyi kararlar alınabilmesine neden olmaktadır. Bu ilişki daha iyi öngörülerin nasıl elde edilebileceği sorusunu ilgi merkezi konumuna getirmektedir. Bu yönde, öngörü modellemesi yöntemlerinin geliştirilmesine yönelik çalışmalar olduğu gibi öngörü değerlendirme ve öngörülerin geliştirilmesi için kullanılacak tekniklere (örneğin öngörü birleştirme teknikleri¹²⁰) yönelik çalışmalar da bulunmaktadır.

Bu çalışmanın konusunu oluşturan Yapay Sinir Ağları yöntemi ekonomi alanında ve başka bir çok alanda öngörü modellemesi için kullanılan yeni bir yöntemdir. Dolayısıyla, öngörü modellemesi tekniklerinin geliştirilmesi ve çeşitlendirilmesi çalışmalarına dahil olmuş bulunmaktadır. Bundan önceki bölümlerde teorisi ve uygulaması anlatılan YSA modelleme tekniğinin, bu bölümde diğer modellerle birlikte bir öngörü karşılaştırması yapılmaktadır. Bu karşılaştırma için, Bölüm 4'te tahmin edilen modellerden elde edilen öngörüler üzerinde bazı öngörü değerlendirme analizleri uygulanmaktadır.

¹²⁰ Bkz. Diebold ve Lopez (1995)

Öngörü değerlendirmesi, öngörülerin kalitesini belirlemeye yarayan karmaşık bir işlem olarak tanımlanabilmektedir ve öngörülerin kalitelerini artırabilmek açısından da önemli bir kavramdır. Bu ifadede kalite terimi doğruluk (accuracy), sapma (bias) veya beceri (skill) gibi bir çok ölçüyü içerebilir. Öngörü doğruluğunun ölçülmesinde öncelikli konu bir kayıp fonksiyonunun belirlenmesidir. Kayıp fonksiyonunun belirlenmesi önemlidir çünkü aynı zamanda uygun bir doğruluk ölçüsünün belirlenmesi anlamına gelmektedir. Örneğin, ikinci dereceden (quadratic) kayıp fonksiyonu, MSE¹²¹ kullanılması anlamına gelmektedir. Kayıp fonksiyonu, öngörü ve gerçekleşme verilerin bir fonksiyonudur:

$$L(y_{t+k}, \hat{y}_{t+k,t}) \xrightarrow{\text{Kısıtlama}} L(e_{t+k,t})$$

Burada, t+k dönemindeki gerçekleşme değeri ve t+k dönemi için t döneminde yapılan öngörü temsil ederken $e_{t+k,t} = y_{t+k} - \hat{y}_{t+k,t}$ olarak tanımlanmaktadır. Öngörü doğruluğunun ölçülmesinde başka bir önemli kavram ise öngörü uzunluğudur (forecast horizon). Çünkü, farklı kayıp fonksiyonları ile değişik öngörü sıralamaları ortaya çıkabileceği gibi, farklı öngörü aralıkları için farklı sıralamalar da oluşabilmektedir.

Öngörü doğruluğunu ölçmek için kullanılacak birçok ölçü bulunmaktadır. Bunlar arasından kullanılacak doğruluk ölçüsünün seçimi için yapılacak analizin konusu ve amacı önem kazanmaktadır. Örneğin, bir zaman serileri seti içinde doğruluk karşılaştırması yapılacaksa, ölçeği, seriler arasındaki nispi öngörü zorlukları ve incelenecek öngörü sayısını kontrol etmek önem kazanmaktadır. Dolayısıyla, uygun kayıp fonksiyonunun incelenen duruma göre değişebileceği unutulmamalıdır¹²². Genel olarak, çeşitli doğruluk ölçülerinin avantajları üzerinde fikir birliği sağlanmıştır¹²³. Bu doğruluk ölçülerinin temelini, sapmayı ölçmek için kullanılan Ortalama Hata (ME – Mean Error) kavramı oluşturur:

$$ME = \frac{1}{T} \sum_{t=1}^T e_{t+k,t} \quad (15)$$

¹²¹ Ortalama Hata Kareleri Toplamı – Mean Squared Errors

¹²² Bkz. Diebold (1993)

¹²³ Bkz. Clements ve Hendry (1993)

Yukarıdaki formülde T öngörü aralığını, t zaman operatörünü, k öngörü uzunluğunu ve e daha önce belirtildiği gibi öngörü hatasını göstermektedir. Ortalama hata kavramını temel alan ve yaygın şekilde kullanılan başlıca doğruluk ölçüleri arasında MSE, RMSE ve MAE sayılabilir¹²⁴. Bu ölçülerin formülleri aşağıda verilmiştir.

$$MSE = \frac{1}{T} \sum_{t=1}^T e_{t+k,t}^2 \quad (16)$$

$$RMSE = \sqrt{\frac{1}{T} \sum_{t=1}^T e_{t+k,t}^2} \quad (17)$$

$$MAE = \frac{1}{T} \sum_{t=1}^T |e_{t+k,t}| \quad (18)$$

Bu öngörü doğruluk ölçüleri arasında en yaygın şekilde kullanılanı MSE'dir. Bu ölçünün önemli bir özelliği, öngörü hatasının varyans toplamlarına ayrıştırılabilmesidir. Bu özellik, MSE ölçüsünün sadece gerçekleşme ve öngörülere ait birleşik dağılımın ikinci momentine bağlı olduğunu göstermektedir. Dolayısıyla, yararlı bilgiler sağlayan bir ölçüdür. Bununla beraber, gerçek dağılımla ilgili tam bilgi sağlayamadığı da belirtilmelidir.

$$\begin{aligned} MSE &= E[(y_{t+k} - \hat{y}_{t+k,t})^2] \\ &= \text{var}(y_{t+k} - \hat{y}_{t+k,t}) + (E[y_{t+k}] - E[\hat{y}_{t+k,t}])^2 \end{aligned} \quad (19)$$

Diğer taraftan, yukarıda anlatılan doğruluk ölçülerinde öngörü hatası (e) yerine öngörü hatasının yüzdesi $(p_{t+k,t} = (y_{t+k} - \hat{y}_{t+k,t}) / y_{t+k})$ kullanılabilir. Bu durumda ölçüler sırasıyla MPE, MSPE, RMSPE ve MAPE olarak adlandırılmaktadırlar.¹²⁵

¹²⁴ MSE = Ortalama Hata Kareleri (Mean Squared Error), RMSE = Ortalama Hata Kareleri Kökü (Root Mean Squared Error) ve MAE = Ortalama Mutlak Hata (Mean Absolute Error)

¹²⁵ Sırasıyla Ortalama Yüzde Hata (Mean Percent Error), Ortalama Yüzde Hata Kareleri (Mean Squared Percent Error), Ortalama Yüzde Hata Kareleri Kökü (Root Mean Squared Percent Error), Ortalama Mutlak Yüzde Hata (Mean Absolute Percent Error).

$$MPE = \frac{1}{T} \sum_{t=1}^T p_{t+k,t} \quad (20)$$

$$MSPE = \frac{1}{T} \sum_{t=1}^T p_{t+k,t}^2 \quad (21)$$

$$RMSPE = \sqrt{\frac{1}{T} \sum_{t=1}^T p_{t+k,t}^2} \quad (22)$$

$$MAPE = \frac{1}{T} \sum_{t=1}^T |p_{t+k,t}| \quad (23)$$

Doğruluk ölçülerinin dışında, öngörü doğruluklarının karşılaştırılmasına yönelik bazı istatistiksel testler de ortaya konulmuştur. Bu testlere bir örnek Merton (1981) tarafından sunulmuştur. Merton, çalışmasında öngörülerin aynı olduğu sıfır hipotezini öngörülerden birisinin daha iyi olduğu alternatif hipotezi karşısında sınavan bir parametrik olmayan (non-parametric) test kullanmıştır. Daha sonra, Stekler (1987) çalışmasında bu testin sağlam (robust) sonuçlar sağladığını göstermiştir.

Diğer bir örnek ise Diebold ve Mariano (1995) tarafından geliştirilmiştir. İlgili çalışmada önerilen test iki farklı modele ait öngörülerin doğruluklarının karşılaştırılmasını sağlamaktadır. $\hat{y}_{i,t+k}$ ve $\hat{y}_{j,t+k}$ değerlerinin y_{t+k} için sırasıyla i ve j modellerinden elde edilen ve karşılaştırılacak öngörüler olduğunu düşünelim. Diebold ve Mariano tarafından önerilen yöntem bir kayıp fonksiyonu $g(e_{i,t+k})$ için eşit öngörü doğruluğu sıfır hipotezinin test edilmesini içermektedir. Kayıp farklılaşması $d_t = g(e_{i,t+k}) - g(e_{j,t+k})$ olarak tanımlanmaktadır ve bu sayede eşit öngörü doğruluğu anlamına gelmektedir. Önerilen test istatistiği ise aşağıdaki gibidir.

$$A = \frac{d}{\sqrt{V(\bar{d})}} \quad (24)$$

$$\bar{d} = (n - k + 1)^{-1} \sum_{t=T+k}^{T+n} d_t \quad (25)$$

$$V(\bar{d}) = (n - k + 1)^{-1} (\hat{\gamma}_0 + 2 \sum_{l=0}^{k-1} \hat{\gamma}_l) \quad (26)$$

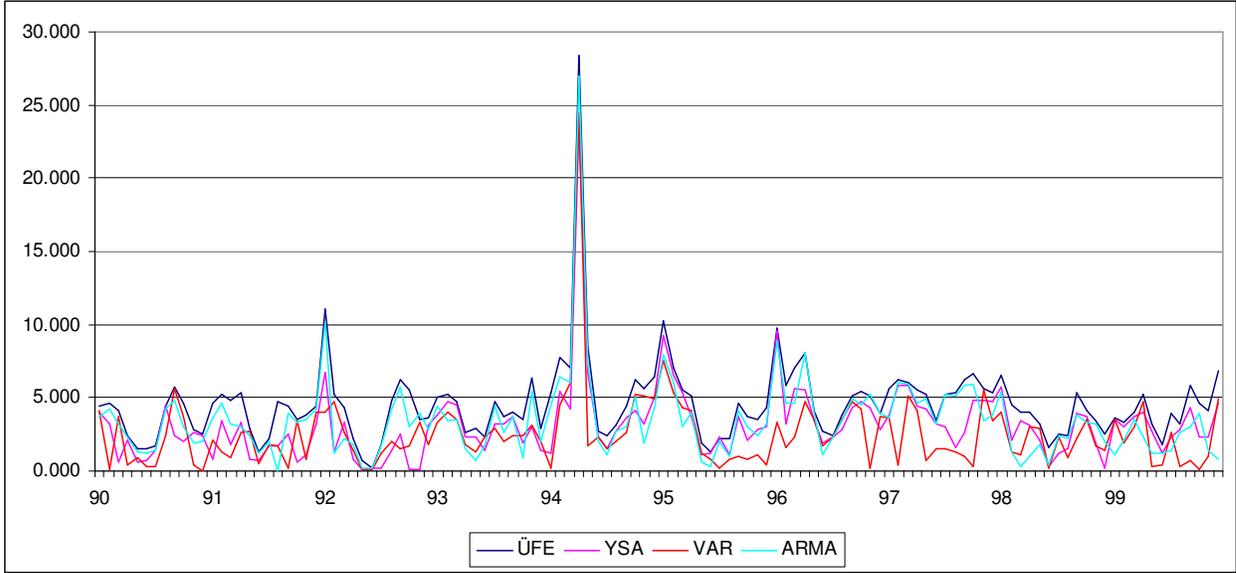
$$\hat{\gamma}_l = (n - k + 1)^{-1} \sum_{t=T+k+l}^{T+n} (d_t - \bar{d})(d_{t-l} - \bar{d}) \quad (27)$$

Bu bölümde, tahmin edilen modellerden elde edilen örneklem içi ve örneklem dışı 1-adım öngörülerin grafikler ve temel istatistikler kullanılarak bir karşılaştırması sunulduktan sonra yukarıda detayları anlatılan öngörü doğruluk ölçüleri çerçevesinde bir öngörü değerlendirmesine yer verilmiştir. Öngörü değerlendirmesinde, tek bir doğruluk ölçüsünün seçilmesi yerine anlatılan tüm ölçüler kullanılmıştır. Son olarak ise Diebold ve Mariano'nun önerdiği test model öngörülerinin karşılaştırılması için uygulanmıştır.

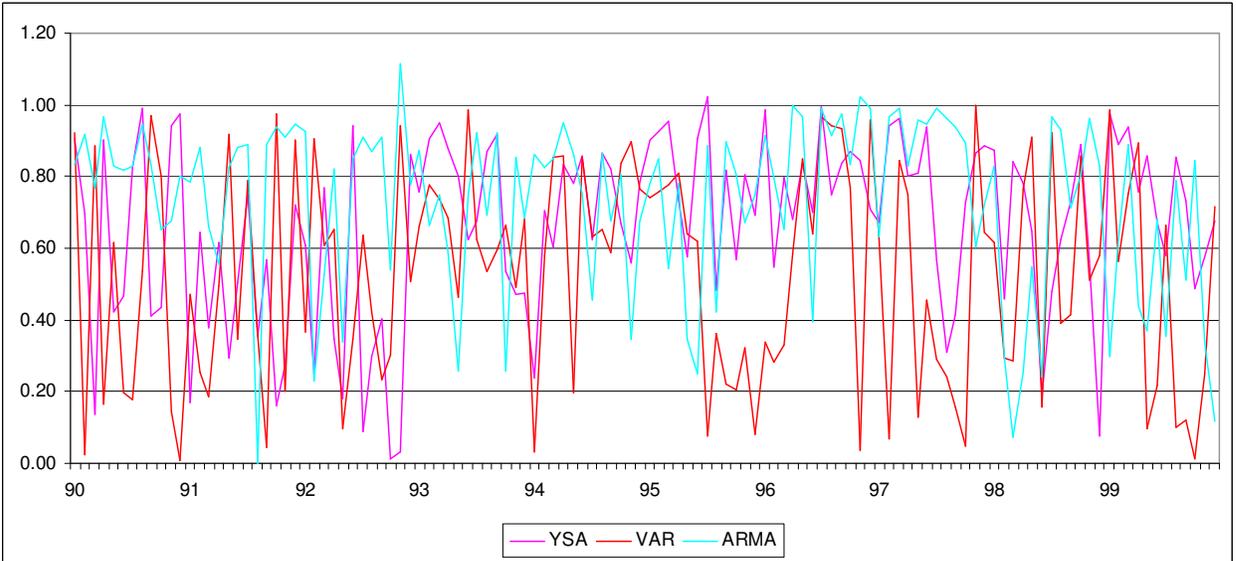
5.1. Modellerin Kıyaslanması

Aşağıda fiyat modellerinden (ARMA, VAR ve YSA) elde edilen öngörülere ait grafikler sunulmaktadır. Grafik 5.1 modellerden elde edilen öngörü ve gerçekleşme fiyat artışlarının bir karşılaştırmasını yansıtmaktadır. Bu öngörü değerlerine ait öngörü hataları ise Grafik 5.2'de karşılaştırılmıştır. Bu grafikler öngörülerin karşılaştırılmasına yönelik somut bilgiler vermese de bazı saptamalar yapmak mümkündür. En azından, genel yapıyı tanımlayamayan veya ıraksama problemi yaşayan modeller grafikler sayesinde basit bir şekilde belirlenebilirler. Enflasyon oranlarını gösteren Grafik 5.1'e göre bu tür problemlere sahip bir öngörü serisi bulunmamaktadır. Grafik 5.2 bu yapıyı daha sağlıklı bir şekilde göstermektedir. Bu grafikten, enflasyon oranının yüksek olduğu dönemler dışında, öngörü hatalarının yaklaşık sıfır ortalama ve sabit varyans yapısına sahip olduğu sonucu çıkarılabilmektedir. Böyle bir yapı öngörülerin doğrulukları açısından kendi içlerinde olumlu bir görüntü sunmaktadır.

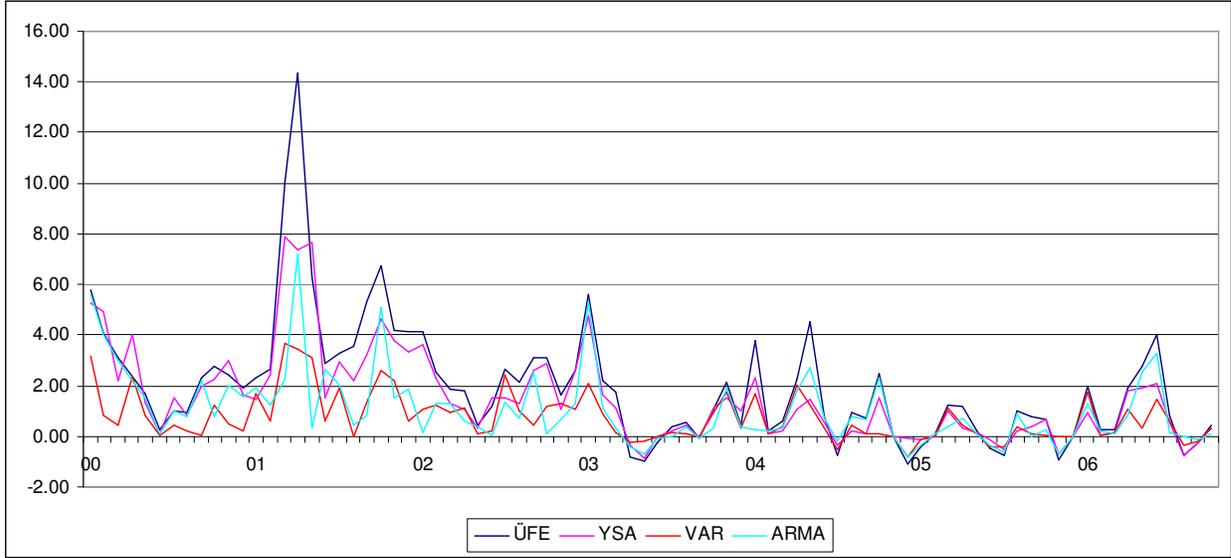
Grafik 5.3 ve Grafik 5.4'te ise Ocak 2000 ve Ekim 2006 dönem aralığını içeren örneklem dışı öngörülere ait karşılaştırmalar verilmiştir. Öngörü doğruluklarının değerlendirilmesinde ve karşılaştırılmasında örneklem dışı öngörüler daha büyük önem taşımaktadırlar. Çünkü model tahmininde kullanılmayan yeni verilere ait öngörülerden oluşmaktadırlar ve bilinmeyen döneme ait tahminleri içermektedirler. Ayrıca, geniş bir dönemi kapsamalarından dolayı grafiklere bakarak öngörülerin karşılaştırılması açısından daha açıklayıcı gözükmemektedirler. Gerçekleşme ile birlikte öngörü enflasyon oranlarını karşılaştıran Grafik 5.3 ve öngörü hatalarını karşılaştıran Grafik 5.4, Şubat 2001 krizinin etkilerini içeren Mart-Nisan 2001 dönemi dışında model öngörülerinin başarılı sayılabileceğini göstermektedir. Ayrıca, öngörü hatalarını gösteren grafiğe göre YSA modelinin örneklem dışı öngörülerde daha başarılı olduğu söylenebilir.



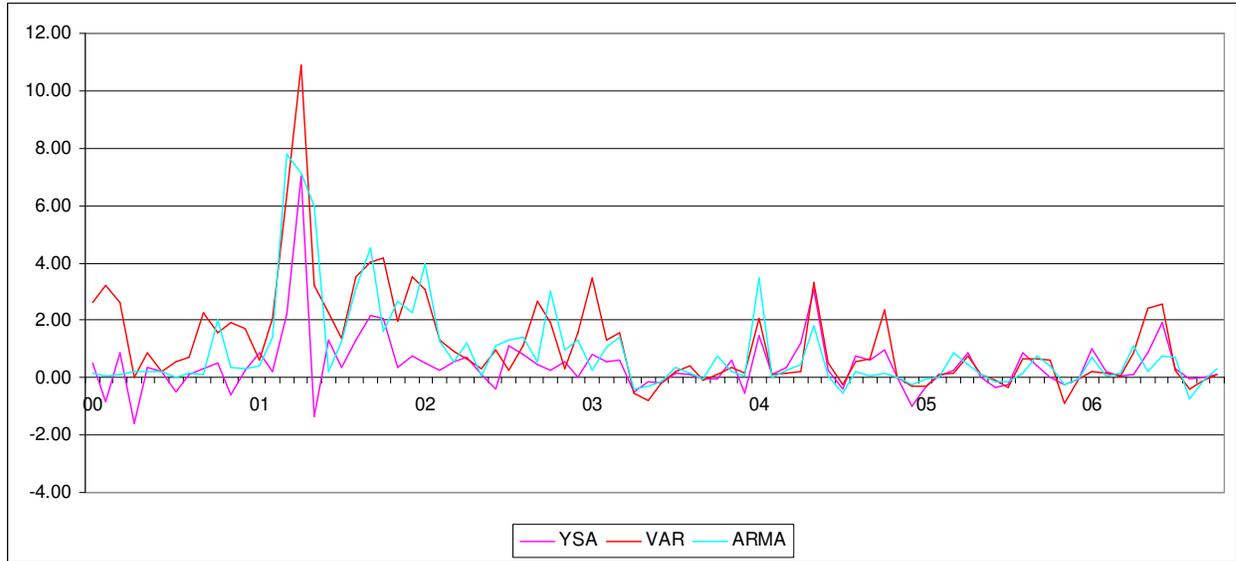
Grafik 5.1: Örneklem İçi Öngörü Karşılaştırması (%)



Grafik 5.2: Örneklem İçi Öngörü Hataları Karşılaştırması (%)



Grafik 5.3: Örneklem Dışı Öngörü Karşılaştırması (%)



Grafik 5.4: Örneklem Dışı Öngörü Hataları Karşılaştırması (%)

Öngörülerini karşılaştırmak için yapılan grafik analizleri, bazı temel istatistikler kullanılarak bir adım ileri götürülebilir. Tablom 5.1 öngörü hatalarına ait temel istatistikleri göstermektedir. Örneklem içi döneme bakıldığında, ortalama açısından ARMA ve VAR modelleri, medyan ve standart sapma açısından YSA modeli daha başarılı gözükmektedir. Örneklem dışı dönemde ise tüm istatistiklere göre en başarılı yöntem olarak YSA modeli görülmektedir. Temel istatistiklere göre yapılan bu tür bir analiz ile daha kesin yargılara varmak mümkünse de, hatalı sonuçlar elde etmek de mümkündür. Ayrıca, istatistiklerin farklı sonuç vermesi durumunda hangi istatistiğin geçerli olduğunu bilmek oldukça zordur. Örneğin, örneklem içi dönemde ARMA ve YSA modelleri arasındaki karşılaştırmada olduğu gibi, ortalamanın küçük, varyansın büyük olması durumunda kesin bir sonuç için daha geniş bir analiz gerekmektedir.

Tablo 5.1: Öngörü Hatalarına Ait Temel İstatistikler

Örneklem İçi Dönem			Örneklem Dışı Dönem			
ARMA	VAR	YSA	ARMA	VAR	YSA	YSA
Ortalama	0.000	0.000	0.012	-0.105	-0.072	0.056
Medyan	-0.059	-0.121	-0.005	-0.933	-0.921	-0.631
Maksimum	7.838	7.844	6.630	7.078	8.024	6.550
Minimum	-6.890	-6.477	-4.161	-2.753	-3.317	-2.438
Std. Sapma	1.506	1.480	1.485	2.569	2.700	1.986
Gözlem	120	120	202	82	82	82

Bu daha geniş analiz ihtiyacı, bölüm başında açıklanan doğruluk ölçüleri tarafından karşılanabilmektedir. Bu yüzden, bu doğruluk ölçüleri üzerinde bir fikir birliği sağlanmıştır. Tablo 5.2 fiyat modellerine ait öngörüler için hesaplanan bu doğruluk ölçülerinin sonuçlarını göstermektedir. Sunulan ölçülerden çıkan en önemli sonuç, örneklem dışı dönemde bütün ölçülerin YSA modelini en doğru öngörülere sahip model olarak göstermesidir. ME ve MPE dışındaki ölçülere göre ikinci başarılı model olarak ise ARMA modeli ortaya çıkmaktadır. Örneklem içi dönemde ise karar vermek zor gözükmektedir. Çünkü, hata ölçüleri en iyi model olarak VAR modeli işaret ederken, yüzde hata ölçülerinden farklı sonuçlar çıkmaktadır.

Tablo 5.2: Öngörü Doğruluk Ölçüleri

	ARMA	VAR	YSA		ARMA	VAR	YSA
Örneklem İçi Dönem							
ME	-0.0000	0.0000	0.0001	MPE	-0.0002	-0.0002	-0.0001
MSE	0.0002	0.0002	0.0002	MSPE	0.0002	0.0002	0.0002
RMSE	0.0150	0.0147	0.0148	RMSPE	0.0143	0.0140	0.0140
MAE	0.0107	0.0105	0.0108	MAPE	0.0102	0.0101	0.0104
Örneklem Dışı Dönem							
ME	-0.0010	-0.0007	0.0005	MPE	-0.0016	-0.0013	0.0000
MSE	0.0006	0.0006	0.0003	MSPE	0.0005	0.0005	0.0003
RMSE	0.0250	0.0263	0.0193	RMSPE	0.0228	0.0239	0.0176
MAE	0.0170	0.0180	0.0125	MAPE	0.0159	0.0169	0.0117

Doğruluk ölçüleri en yaygın metot olmasına ve yeterli derecede tanımlanmasına rağmen, en azından bir kontrol mekanizması olarak kullanılabileceği düşüncesi ile, bu çalışmada ek bir analize yer verilmiştir. Bölümün başında açıklanan Diebold ve Mariano Test İstatistiği kullanılarak model öngörülleri örneklem dışı dönem içinde ikişerli olarak test edilmişlerdir. Yüzde 5 anlamlılık düzeyinde gerçekleştirilen bu testlerin sonucunda YSA modeli diğer iki modele karşı üstün çıkarken VAR ve ARMA modellerin öngörü doğrulukları istatistiksel olarak eşit çıkmıştır.

6. SONUÇ

Bu çalışmada, öngörü modellemesi yöntemi olarak Yapay Sinir Ağları (YSA) metodolojisinin kullanımı araştırılmıştır.

Çok sayıdaki YSA mimarisi arasından kullanışlı olması nedeniyle Geri Yayılma Yapay Sinir Ağı (GYYYSA) mimarisi modellemede tercih edilmiştir. GYYSA mimarisi kullanılarak fiyat değişkeni (Üretici Fiyat Endeksi - ÜFE) için bir örneklem aralığı ile eğitim yapılmış ve ardından ilerleyen dönemler için gerçekleşmesi muhtemel değerler tahmin edilmiştir. Diğer taraftan, YSA modellerinin öngörü performansları VAR (Vektör Otoregresyon) ve Box-Jenkins (ARMA) modelleme teknikleri kullanılarak tahmin edilen modellerin öngörü performansları ile karşılaştırılmıştır. Ayrıca, karşılaştırmaların yorumlanabilir olması için farklı yöntemlerin mümkün olduğunca benzer yapı taşımalarına özen gösterilmiştir.

Tahmin edilen YSA modelleri kendi içlerinde tutarlı bir yapı ve iyi bir öngörü performansı sergilemişlerdir. VAR ve Box-Jenkins (ARMA) modelleri ile yapılan öngörü karşılaştırmalarında ise YSA metodolojisinin diğer yöntemlere göre daha iyi bir öngörü performansına sahip olduğu sonucuna varılmıştır. Karşılaştırmalarda en dikkat çekici nokta YSA modellerinin örneklem içi dönemde diğer modelleme tekniklerine göre daha zayıf bir performansa sahip olmasına rağmen örneklem dışı dönemde en iyi performansı sağlayan yöntem olmasıdır. Bu durum, örneklem içi dönemde diğer modellerin performansını yakalayacak YSA modellerinin çok daha başarılı öngörü performansı sağlayabileceği şeklinde yorumlanabilir. Bu da YSA modelleme tekniğinin daha etkili bir öngörü modellemesi tekniği olduğu ifadesini güçlendirmektedir.

Bu çalışma esnasında YSA uygulaması çalıştırılırken sadece sınırlı sayıda etkene dayanılarak hesaplama yapıldığı göz ardı edilemeyecek bir unsurdur. Sistem içerisine eklenen her bir değişkenin artan hesaplama süresi ile birlikte sonuçların doğruluk oranlarına etki edeceği göz önüne alınmalıdır. Dikkat çekici bir başka nokta ise, YSA modeline mevsimsel etkiler yansıtılmamış olmasına rağmen diğer modellerden üstün performans sağlamış olmasıdır. Ek olarak, mevsimsel etkilerin yansıtılması durumunda YSA modellerinin performansının yükseleceği de açıktır.

Sonuçlar, aşırı eğitim, mimarinin hatalı oluşturulması vb. problemleri olmayan YSA modellerinin öngörü gücü yüksek ekonometrik modellere göre daha iyi öngörü performansı sağlayabildiğini göstermektedir. Diğer taraftan YSA metodolojisinin doğrusal olmayan bir yöntem olduğu göz önüne alınmalıdır. Bu çerçevede YSA metodolojisi doğrusal yöntemler ile karşılaştırıldığında Türkiye ekonomisine ait değişkenler için doğrusal olmayan modellemenin daha etkili olduğu yönünde bir genelleme yapmak hatalı olmayacaktır.

KAYNAKLAR

- Alexander, I. & Morton, H. An Introduction to Neural Computing. London: Chapman and Hall, 1990.
- Akad, A., Savaş. “*TEFE Endeksi*”, Sabah Gazetesi, 10 Mart 2002.
- Akad, A., Savaş. “*TÜFE Endeksi*”, Sabah Gazetesi, 14 Mart 2002.
- Akdiş, Muhammet. Para Teorisi ve Politikası, Beta Yayıncılık, 1.Baskı, İstanbul, 2001.
- Alpar, Cem. İktisat, Evrim Yayıncılık, 5. Baskı, İstanbul, 1988.
- Altuğ, S. “*İstanbul Menkul Kıymetler Borsası’nda Yapay Sinir Ağları Kullanılarak Fiyat Öngörüsü*”. Yüksek Lisan Tezi, Bilkent Üniversitesi, 1994.
- Anderson, D. ve McNeil, G. “*Artificial Neural Networks Technology*”, Data & Analysis Center for Software, 1992.
- Balkin, S. D. (1997), “*Using Recurrent Neural Networks For Time Series Forecasting*,” Working Paper, 97-11, Department of Management Science and Information Systems, Pennsylvania State University, 1997.
- Balkin, S. D. (2001), “*Statistical Aspects of Neural Networks*”, Notes of Presentation to Washington Statistical Society, Ernst & Young LLP, 2001.
- Baylar, A., Emiroğlu, M. E. ve Arslan, A. (1999), “*Geriye Yayılma Yapay Sinir Ağı Kullanılarak Yanal Su Alma Yapısına Yönelecek Olan Sürüntü Maddesi Oranının Bulunması*”, Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi, 1999, Sayı 1, s 1-12.
- Beltratti, A. & Margarita, S. ve Terna, P. Neural Networks for Economic and Financial Modelling, International Thomson Computer Pres, 1996.
- Biçerli, M., Kemal. Çalışma Ekonomisi, Beta Yayıncılık, 1.Baskı, İstanbul, 2001.
- Box, G.E.P. & Jenkins, G. “*Distribution of Residual Autocorrelations in Autoregressive Integrated Moving Average Models*”, Journal of American Statistics Association, Sayı 65, 1970, s 1509-1526.

Box, G.E.P. ve Jenkins, G. Time Series Analysis: Forecasting and Control, Holden Day, San Fransisco, 1970.

Church, K. B. ve Curram, S. P. “*Forecasting Consumers’ Expenditure: A Comparison Between Econometric and Neural Network Models*”, International Journal of Forecasting, Sayı 12, 1996, s 255-267.

Clements, M.P. ve Hendry, D.F. “*On the Limitations of Comparing Mean Squared Forecast Errors*”, Journal of Forecasting, Sayı 12, 1993, s 617-638.

DARPA “*Neural Network Study*”, 2004.

Dickey, D. ve Fuller, W. A. “*Distribution of the Estimates for Autoregressive Time Series With a Unit Root*”, Journal of the American Statistical Association, Sayı 74, 1979. s 427-431.

Dickey, D. ve Fuller, W. A. “*Likelihood Ratio Statistics for Autoregressive Time Series with a Unit Root*”, Econometrica, Sayı 49, 1981. s1057-1072.

Diebold, F.X. “*On the Limitations of Comparing Mean Square Forecast Errors: Comment*”, Journal of Forecasting, Sayı 12, 1993. s 641-642.

Diebold, F. X., and Lopez. J. A. “*Forecast Evaluation and Combination*”, Research Paper, Federal Reserve Bank of New York, 1995.

Diebold, F. X. ve Mariano, R. “*Comparing Predictive Accuracy*”, Journal of Business and Economic Statistics, Sayı 13, 1995, s 253-264.

El Shazly, M. R. ve El Shazly, H. E. “*Comparing the Forecasting Performance of Neural Networks and Forward Exchange Rates*”, Journal of Multinational Financial Management, Sayı 7, 1998, s 345-356.

Enders, W. Applied Econometric Time Series, John Wiley & Sons, Inc. 1995.

Gujarati, D. N. Basic Econometrics, McGraw-Hill, Inc. 1995.

Gülseçen, S. “*Yapay Sinir Ağları İşletme Alanında Uygulanması ve Bir Örnek Çalışma*”, Doktora Tezi, İstanbul Üniversitesi. 1999.

Hamilton, J. D. Time Series Analysis, Princeton University Press. 1994.

Harvey, A. Forecasting, Structural Time Series Models, and the Kalman Filter, Cambridge: Cambridge University Press. 1989.

Haykin, S. Neural Networks A Comprehensive Foundation, Prentice Hall International, Inc. 1999.

Heinemann, M. “*Adaptive Learning of Rational Expectations Using Neural Networks*”, Journal of Economic Dynamics & Control, Sayı 24, 2000, s 1007-1026.

Hill, T., Marquez, L., O’Connor, M. ve Remus, W. “*Artificial Neural Network Models for Forecasting and Decision Making*”, International Journal of Forecasting, Sayı 10, 1994, s 5-15.

Janacek, G. ve Swift, L. Time Series Forecasting, Simulation, Applications, Ellis Horwood Limited. 1993.

Kadılar, C. Uygulamalı Çok Değişkenli Zaman Serileri Analizi, Hacettepe Üniversitesi. 2000.

Kocabaş, Şakir. Yapay Zeka Ders Notları, İstanbul Teknik Üniversitesi. 1998-1999.

Kohonen, T. “*Self-organised Formation of Topologically Correct Feature Maps*”, Biological Cybernetics, Sayı 43, 1983, s 59-69.

Kramer, A. H. ve Sangiovanni-Vincentelli, A. “*Efficient Parallel Learning Algorithms for Neural Networks*”, Advances in Neural Information Processing Systems, Sayı 1, 2005, s 40-48.

Leung, M. T., Daouk, H. ve Chen, A. “*Forecasting Stock Indices: A Comparison of Classification and Level Estimation Models*”, International Journal of Forecasting, Sayı 16, 2004, s 173-190.

Malsburg, C. “*Self-organisation of Orientation Sensitive Cells in the Striate Cortex*”, Kybernetik, Sayı 14, 1986, s 85-100.

McCulloch, W. S. ve Pitts, W. “*A Logical Calculus of the Ideas Immanent in Nervous Activity*”, Bulletin of Mathematical Biophysics, Sayı 5, 1943, s115-133.

Merton, R. C. ve Henriksson, R. D. “*On Market Timing and Investment Performance 2: Statistical Procedures for Evaluating Forecasting Skills*”, Journal of Business, Sayı 54, 1981, s 513-433.

Minsky, M. L. ve Papert, S. A. Perceptrons, Cambridge, MA: MIT Press. 1969.

Montgomery, D. C., Johnson, L. A. ve Gardiner, J. S. Forecasting & Time Series Analysis, McGraw Hill, Inc. 1990.

Parker, D. B. “*Optimal Algorithms For Adaptive Networks: Second Order Back Propagation, Second Order Direct Propagation, and Second Order Hebbian Learning*”, IEEE 1st International Conference on Neural Networks, Sayı 2, 1987, s 953-600, San Diego, CA.

Parasız, İlker. Makro Ekonomi, Ezgi Kitabevi, Bursa, 1998.

Paya, Merih: Para Teorisi ve Politikası, Filiz Kitabevi, 2.Baskı, İstanbul, 1998.

Rumelhart, D. E., Hinton, G. E. ve Williams, R. J. “*Learning Representations of Back-propagation Errors*”, Nature (London), Sayı 323, 1986, s 533-536.

Seyidođlu, Halil. Ekonomik Terimler Ansiklopedik Sözlük, 2.Baskı, İstanbul, 1999.

Sims, C. “*Macroeconomics and Reality*”, Econometrica, Sayı 48, 1980, s 1-49.

Stekler, H O. “*Are Economic Forecasts Valuable?*”, Journal of Forecasting, Sayı 13, 1994, s 495-505.

Swanson, N. R. ve White, H. “*Forecasting Economic Time Series Using Flexible Versus Fixed Specification and Linear Versus Nonlinear Econometric Models*”, International Journal of Forecasting, Sayı 13, 2003, s 439-461.

Tkacz, G. “*Neural Network Forecasting of Canadian GDP Growth*”, International Journal of Forecasting, Sayı 17, 2004, s 57-69.

Unay, Cafer. Genel İktisat, Ekin Kitabevi, Bursa, 1997.

Üstünel, Besim: Makro Ekonomi, Mısırlı Matbaacılık, 5.Baskı, İstanbul, 1990.

Üngör, A. “*Yapay Sinir Ağları ve Box-Jenkins Modeli Kullanarak Döviz Kuru Tahmini*”, Yüksek Lisans Tezi, Orta Doğu Teknik Üniversitesi. 1998.

Wegmann, G. “*Future Extraction With Hybrid Neural Networks*”, Research Notes in Economics & Statistics, Deutsche Bank Research. 2005.

Willshaw, D. J. ve Malsburg, C. “*How Patterned Neural Connections Can Be Set Up By Self-organisation*”, Proceedings of the Royal Society of London Series B, Sayı 194, 1976, s 431-445.

Yıldız, B. “*Finansal Başarısızlığın Öngörülmesinde Yapay Sinir Ağı Kullanımı ve Halka Açık Şirketlerde Ampirik Bir Uygulama*”, İMKB Dergisi, Sayı 17, 2001, s 51-68.

Yurtoğlu, Hasan. “*Yapay Sinir Ağları Metodolojisi İle Öngörü Modellemesi: Bazı Makroekonomik Değişkenler İçin Türkiye Örneği*”, Uzmanlık Tezi, Devlet Planlama Teşkilatı. 2005.

Zurada, J. M. Introduction to Artificial Neural Systems, West St. Paul. 2005

Ek 1. Durdurma Kriteri

Ağırlık ayarlama (öğrenme) sürecini bir noktada durdurmak için kullanılabilecek bazı makul kriterler vardır. Bu tür bir kriteri formüllemek için hata yüzeyine ait yerel veya genel minimum değerlerden yararlanılmaktadır. w^* ağırlık vektörünün bir minimum değeri (yerel veya genel) gösterdiği düşünülürse, w^* vektörünün minimum noktayı göstermesi için gerekli şart, $g(w)$ değişme (gradient) vektörünün $w=w^*$ noktasında sıfır değeri almasıdır. Buna göre, Geri Besleme öğrenme süreci için bir yakınsama kriteri oluşturulabilmektedir (Kramer ve Sangiovanni-Vincentelli, 1989).

“Değişme vektörünün Euclidean normu yeterince küçük bir eşiğe ulaşıncaya geri besleme algoritmanın yakınsadığı söylenebilir.”

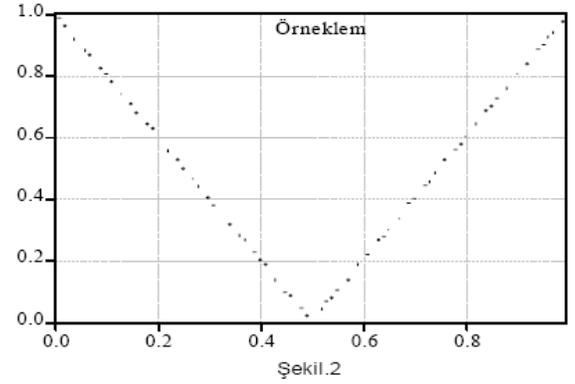
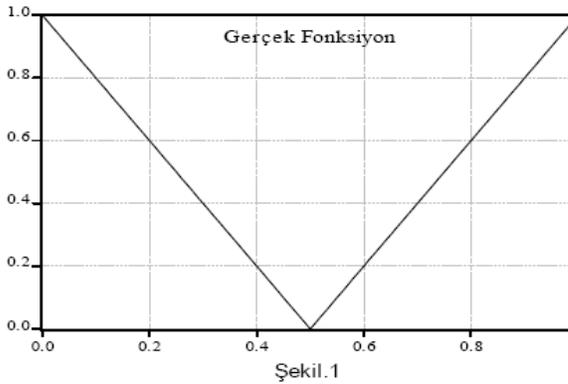
Bu yakınsama kriterinin dezavantajı, başarılı bir yakınsama için öğrenme süresinin uzun olabilmesidir. Ayrıca, değişme vektörünün hesaplanmasını gerektirmesi de diğer bir dezavantaj olarak görülebilir. Hata ölçüsünün (maliyet fonksiyonu olarak) $w=w^*$ noktasında durağan olmasını gerektiren özelliğin kullanılması ile başka bir kriter oluşturulabilir.

“Bir döngü (epoch) için ortalama hata karesindeki değişimin mutlak değeri yeterince küçüldüğünde geri besleme algoritmanın yakınsadığı söylenebilir.”

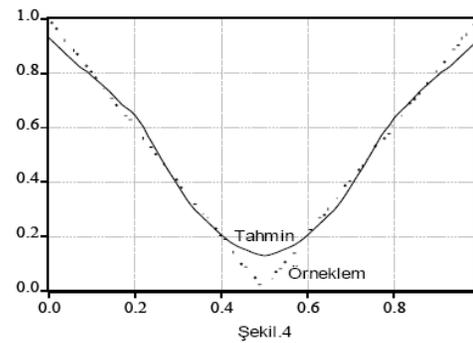
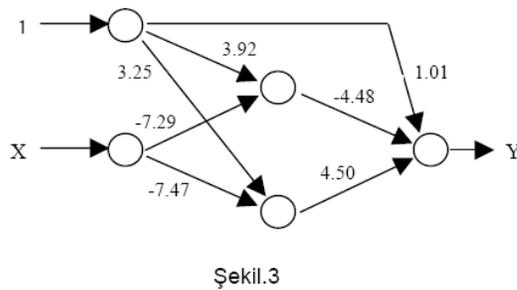
Bu kriterde, ortalama hata karesindeki değişim için minimum değer araştırmacı tarafından belirlenmektedir. Ayrıca, bazı durumlarda bu yöntem öğrenme işleminin erken durdurulmasına neden olabilmektedir. Yakınsama için, teorik olarak kanıtlanmış başka bir kriter daha vardır. Bu kriterde, her öğrenme döngüsünden sonra ağırlıkların genelleme performansı test edilir ve öğrenme işlemi bu genelleme performansı yeterli bir düzeye ulaştığında sona erdirilir.¹²⁶

¹²⁶ Bu kriterin detayı için bakınız: Haykin (1999), Bölüm 4.14

Ek 2. YSA'ların Çalışma Şekli İçin Örnek Çözüm



Şekil.1'de tahmin edilmek istenen doğrusal olmayan bir yapı, Şekil.2'de ise tahmin edilecek bu yapıdan rasgele elde edilmiş gözlemler gösterilmektedir. Şekillerin x-eksenlerini girdi olarak kullanarak, Şekil.2'deki gözlemleri tahmin etmek için basit bir ileri besleme YSA oluşturulmaktadır. Oluşturulan bu YSA modeli Şekil.3'te verilmektedir. Bir girdi tabakası, bir gizli tabakası ve bir de çıktı tabakası olan bu iki tabakalı ileri besleme ağ girdi ve çıktı tabakalarında birer, gizli tabakasında ise iki nörona sahiptir. Bu YSA mimarisi, dışsal etkileri içeren sapma değerinin de eklenmesiyle tahmin edildiğinde Şekil.3'teki mimari ortaya çıkmaktadır. Tam bağlantı içeren bu yapıda okların yanındaki rakamlar tahmin edilen ilgili bağlantı ağırlıklarını göstermektedir. Basit bir şekilde tahmin edilen bu modelin örneklem içi öngörülerini Şekil.4'te örnek gözlemlerle karşılaştırmalı olarak verilmektedir. Şekilden de görülebileceği gibi gizli nöronlara sahip bir ileri besleme YSA (basit olmasına rağmen) doğrusal olmayan bir yapıyı oldukça iyi bir şekilde tanımlayabilmektedir.¹²⁷



¹²⁷ Bu örnek çözüm Balkin (2001)'den alınmıştır.

Ek 3. Gizli Nöron Sayısı İçin Üst Limit Kriteri

Eldeki, eğitime için kullanılan veri setinin genişliği, gizli tabakalardaki nöron sayısına bir üst limit oluşturabilmektedir. Bu üst limitin belirlenmesinde kullanılacak bir yöntem şu şekilde özetlenebilir:

Üst limiti hesaplamak için, eğitime setindeki girdi-çıkıtkı ikililerinin sayısı kullanılır. Bu sayı, ağdaki toplam girdi ve çıkıtkı nöronu sayısına bölünür. Elde edilen sonuç, bir ölçeklendirme katsayısı (genellikle $5 < Z < 10$) olarak kullanılabilir. Burada, daha büyük ölçeklendirme katsayısının daha fazla hata içeren (noisy) veri seti için kullanıldığı söylenebilir. Hatta, aşırı derecede hata içeren veri seti için çok daha büyük katsayılar (örneğin 20 veya 50) kullanılabilir. Diğer taraftan, hemen hemen hiç hata içerilmemesi durumunda ise katsayı 2 seviyesine kadar indirilebilir. Bu noktada, veri setine yönelik analiz önem kazanmaktadır. Bu yöntemle, ölçeklendirme katsayısının ne olacağına bağlı olarak kesin bir neticeye ulaşılmasa da, yaklaşık bir fikir edinmek mümkündür. Ayrıca, genelleme özelliğinin kaybolabilmesi ve dolayısıyla ağın yeni veriler tanıtıldığında kullanışsız kalması sonucunu doğurabileceğinden, bir gizli tabakadaki nöron sayısının çok fazla olmaması yararlı olacaktır.

Ek 4. Öğrenme Kuralları

Yapay Sinir Ağlarında çok sayıda öğrenme kuralı kullanılmaktadır. Bu öğrenme kurallarının büyük çoğunluğu en eski ve en çok bilinen öğrenme kuralı olan Hebb Kuralının bir versiyonudur. Bunların yanında, farklı öğrenme kuralı fonksiyonları da vardır ve bu konuda çalışmalar sürmektedir. Bazı araştırmacılar temel amaç olarak biyolojik öğrenmeyi modellemenin peşindedirler. Bazıları ise eldeki öğrenme hakkındaki bilgilerin bir şekilde uyarlanmasına çalışmaktadır. Her iki noktada da, sinirsel işlemin gerçekte nasıl olduğuna yönelik bilgiler oldukça kısıtlıdır. Dolayısıyla öğrenme, kullanılmakta olan öğrenme kurallarının ima ettiğinden çok daha komplikedir. Kullanılmakta olan bazı önemli öğrenme kuralları arasında Hebb Kuralı, Hopfield Kuralı, Delta Kuralı, Eğimli Değişim (Gradient Descent) Kuralı ve Kohonen Öğrenme Kuralı sayılabilir. Delta Kuralı metin içinde açıklanmaktadır; burada diğer öğrenme kuralları için bazı temel bilgiler verilmektedir.

Hebb Kuralı: Hebb (1949) tarafından tanımlanmış olan bu kural ilk ve en çok bilinen öğrenme kuralıdır. Temel kural şu şekildedir: Bir nöron başka bir nörondan girdi alırsa ve iki nöron da yüksek derecede aktifse (yani matematiksel olarak aynı işarete sahipse) nöronlar arasındaki bağlantının ağırlığı artırılmalıdır.

Hopfield Kuralı: Bir temel farklılık dışında Hebb Kuralına benzemektedir. Temel farklılık ise bağlantı ağırlığında yapılacak değişikliğin büyüklüğünü de belirlemesidir. Buna göre, girdi ve istenilen çıktının ikisi de aktifse veya ikisi de aktif değilse, bağlantı ağırlığı öğrenme oranı kadar artırılır, aksi durumda ise öğrenme oranı kadar azaltılır.

Eğimli Değişim Kuralı: Bu kurala göre, Delta Kuralında olduğu gibi, delta hatanın modifiye edilmesi için transfer fonksiyonunun türevi kullanılmaktadır.

Eğimli Değişim Kuralının farklılığı, öğrenme oranına orantılı bir ek sabit değer son değiştirme faktörüne eklenmesidir. Bağlantı ağırlığı, bu ek değerli faktöre göre değiştirilir. Bu kural, yavaş bir yakınsama sağlamasına rağmen yaygın olarak kullanılmaktadır.

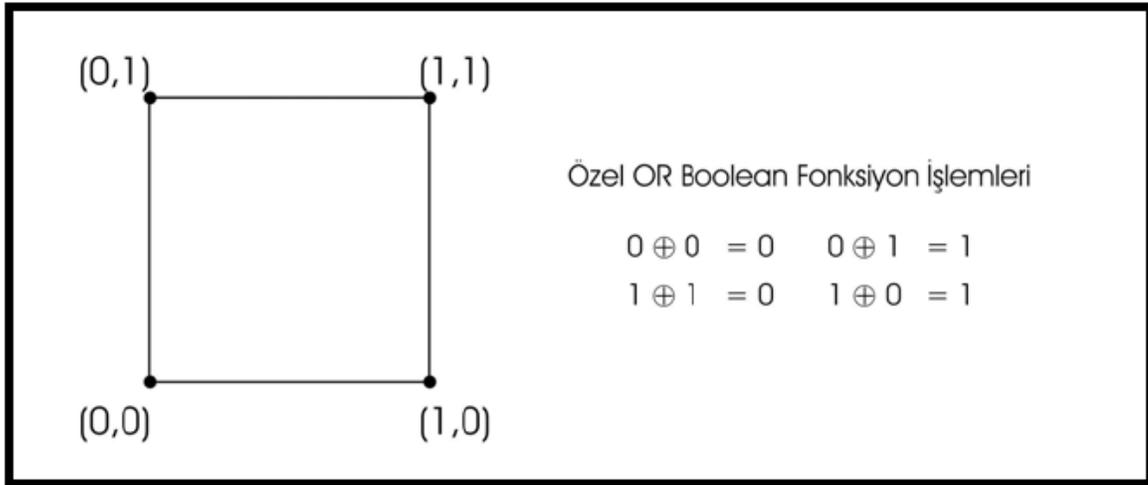
Kohonen Öğrenme Kuralı: Kohonen (1982) tarafından geliştirilen bu kural biyolojik sistemlerdeki öğrenme sisteminden esinlenilmiştir. Bu yöntemde, işlem elemanlarının, ağırlıkları ayarlamak (öğrenmek) için rekabet ettikleri düşünülmektedir. En

uygun ıktıya sahip iřlem elemanı diđerlerine gre baskın olur ve sadece bu nronun ıktı sađlaması sz konusudur. Kendi kendine đrenme (self-organising) olarak da bilinen bu kural zellikle dađlımlara ynelik alıřmalarda kullanılmaktadır fakat teorik alt yapısının tam geliřmemiř olmasından dolayı uygulamada henz yaygınlık kazanmamıřtır.

Burada, en ok bilinen đrenme kuralları hakkında temel bilgiler sunulmaktadır. đrenme kuralları hakkında daha detaylı bilgi iin Haykin (1999)'dan yararlanılabilir.

Ek 5. XOR Problemi

Tek tabaklı Perceptron (ileri besleme ağ) gizli nöronlar içermez, sadece çıktı tabakasına sahiptir. Bu yüzden, doğrusal olarak ayrıştırılmayan girdi yapılarını sınıflandıramaz yani doğrusal olmayan yapıları belirleyemez. Halbuki, doğrusal olmayan yapılar ile hemen hemen her konuda karşılaşılabilir. Bu durum, XOR (Exclusive OR) probleminin basitleştirilmiş bir hali ile örneklenebilmektedir. Bu basitleştirilmiş yapı aşağıdaki şekilde sunulmaktadır.



Şekilde açıklanan fonksiyon, doğrusal olarak ayrıştırılmayan bir yapı içermektedir. 1969 yılında Minsky ve Papert, yazdıkları kitapta bu tür bir yapının tek tabaklı Perceptron ile modellenemediğini ve dolayısıyla sorunlu olduğunu göstermişlerdir. YSA literatüründe XOR Problemi olarak adlandırılan bu sorun YSA üzerine çalışmalarını durma noktasına getirmiştir.

Daha sonra, Touretzky ve Pomerleau (1989)¹²⁸ XOR probleminin YSA’larda gizli nöronlar kullanılarak yani çok tabaklı ağlar yardımıyla aşılabildiğini göstermişlerdir. Bu şekilde, YSA teknolojisi ile doğrusal olmayan yapıların da sınıflandırılabilir oldukları ortaya konulmaktadır.¹²⁹

¹²⁸ Bakınız: Haykin (1999)

¹²⁹ XOR Problemi ile ilgili daha detaylı bilgi için bkz. Haykin (1999) ve Zurada (1992).